

Modelování ledvinových kamenů z UZV obrazů
Modeling of Kidney Stones from Ultrasound Images

VŠB - Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

Zadání diplomové práce

Student: **Bc. Adéla Kloudová**
Studijní program: N2649 Elektrotechnika
Studijní obor: 3901T009 Biomedicínské inženýrství
Téma: **Modelování ledvinových kamenů z UZV obrazů**
Modeling of Kidney Stones from Ultrasound Images
Jazyk vypracování: čeština

Zásady pro vypracování:

1. Nastudování klinických aspektů a funkce ledvin.
2. Nastudování zobrazovacích technik pro vyšetření funkce ledvin a ledvinových kamenů.
3. Rešerše segmentačních metod pro modelování funkce ledvin.
4. Analýza obrazových dat s cílem identifikace ledvinových kamenů.
5. Návrh předzpracování obrazu pro optimalizaci obrazových vlastností ledvinových kamenů.
6. Návrh a optimalizace parametrů segmentační procedury pro detekci ledvinových kamenů.
7. Extrakce geometrických příznaků pro hodnocení modelu ledvinových kamenů.
8. Testování a objektivní evaluace navrženého modelu pro reálná obrazová data.
9. Vyhodnocení dosažených výsledků.

Seznam doporučené odborné literatury:

- [1] JAN, Jiří. *Medical image processing, reconstruction and restoration: concepts and methods*. Boca Raton: Taylor & Francis, 2006. ISBN 0-8247-5849-8.
- [2] SURI, Jasjit S, David Lynn WILSON a Swamy LAXMINARAYAN, ed. *Handbook of biomedical image analysis*. Volume I, Segmentation Models. New York: Kluwer Academic/Plenum Publishers, c2005. ISBN 0-306-48550-8.
- [3] SEMMLOW, John L a Benjamin GRIFFEL. *Biosignal and medical image processing*. 3rd ed. Boca Raton: CRC Press, c2014. ISBN 978-1-4665-6736-8.
- [4] BIRKFELLNER, Wolfgang. *Applied medical image processing: a basic course*. 2nd ed. Boca Raton: CRC Ppress, c2014. ISBN 978-1-4665-5557-0.

Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí diplomové práce: **Ing. Jan Kubíček, Ph.D.**

Datum zadání: 01.09.2018

Datum odevzdání: 30.04.2019



doc. Ing. Jiří Koziorek, Ph.D.
vedoucí katedry



prof. Ing. Pavel Brandštetter, CSc.
děkan fakulty

Prohlašuji, že jsem tuto diplomovou práci vypracovala samostatně. Uvedla jsem všechny literární
prameny a publikace, ze kterých jsem čerpala.

.....
29.4.2019

Datum

.....
Adela Kloučková

Podpis

Poděkování

Na tomto místě bych ráda poděkovala vedoucímu panu Ing. Janu Kubičkovi, PhD., za jeho rady a připomínky při zpracovávání diplomové práce i za jeho ochotu a pevné nervy, paní MUDr. Veronice Hájkové za poskytnuté snímky a v neposlední řadě své rodině a všem přátelům, kteří mi při psaní této práce projevovali obrovskou podporu.

Abstrakt

Tématem diplomové práce byly ledvinové kameny a jejich segmentace na ultrazvukových snímcích. Cílem práce bylo navržení a testování algoritmu pro vytvoření modelu ledvinových kamenů. Pro zpracování práce a splnění jejich cílů bylo klíčové nastudování anatomických, patologických i fyziologických aspektů funkce ledvin, dále metod, které se pro zobrazování ledvinových kamenů používají a v neposlední řadě metod zpracování obrazu, které byly nezbytné pro optimální výsledky práce – tedy metody vhodné pro předzpracování obrazu – filtrace a segmentační metody využívající multiregionální segmentaci a aktivní kontury, díky kterým došlo k vytvoření finálního modelu LK. Celkové vyhodnocení bylo pak provedeno na základě extrahovaných parametrů z modelu – plocha, obvod, délka hlavní a vedlejší poloosy.

Klíčová slova

Ultrazvuková sonografie, ledviny, ledvinové kameny, urolitiáza, zobrazovací metody v medicíně, segmentační metody, filtrace obrazu, multiregionální segmentace, aktivní kontury.

Abstract

The topic of this thesis was kidney stones and their segmentation on ultrasound images. The aim of this work was to design and test an algorithm for the creation of kidney stone model. The key to the thesis was to study the anatomical, pathological and physiological aspects of kidney function, the methods used for kidney stone imaging and, last but not least, the image processing methods that were necessary for optimal results - ie, multi-regional segmentation methods and segmentation using active contours to create the final kidney stone model. The overall evaluation was then based on the extracted parameters from the model – area, perimeter, length of major and minor axis.

Keywords

Ultrasound sonography, kidneys, kidney stones, urolithiasis, segmentation methods, image filtering, multithresholding, multiregional segmentation, active contours.

Obsah

Seznam zkratk a symbolů	9
Seznam obrázků.....	10
Seznam grafů.....	12
Seznam tabulek.....	12
1 Úvod.....	13
2 Anatomie a fyziologie ledvin.....	14
3 Patologie močového ústrojí – onemocnění ledvin	16
3.1 Urolitiáza – onemocnění močovými kameny.....	16
3.2 Vyšetřovací metody a diagnostika ledvinových kamenů	17
4 Ultrazvukové vlnění a jeho využití v medicíně.....	18
4.1 Ultrazvukové vlnění – fyzikální princip	18
4.1.1 Odraz a lom ultrazvukového vlnění	18
4.2 Ultrazvuková sonografie	19
4.3 Ultrazvukové snímače – sondy.....	19
4.3.1 Lineární sondy	20
4.3.2 Sektorové sondy.....	20
4.3.3 Konvexní sondy	20
4.4 Módy zobrazení.....	20
4.4.1 A mód.....	21
4.4.2 B mód.....	21
4.4.3 Trojrozměrné zobrazení – 3D mód	21
4.4.4 M mód	21
4.5 Dopplerovské zobrazování.....	22
5 Segmentační metody pro zpracování biomedicínských snímků	23
5.1 Segmentace pomocí prahování.....	23
5.2 Segmentace pomocí detekce hran.....	24
5.2.1 Metody první derivace	24
5.2.2 Metody druhé derivace.....	25
5.2.3 Cannyho detektor.....	25
5.3 Segmentace pomocí aktivních kontur	26
6 Metody segmentace ledvinových kamenů – rešeršní shrnutí nejnovějších poznatků	27

6.1	Analýza a implementace detekce ledvinových kamenů metodou úrovně segmentace	27
6.1.1	Řešení.....	27
6.2	Detekce ledvinových kamenů na CT snímcích	28
6.2.1	Řešení.....	28
6.2.2	Výsledky testování.....	29
6.3	Diagnostika ledvinových kamenů na UZV snímcích	30
6.3.1	Řešení.....	30
6.3.2	Výsledky testování.....	31
6.4	Automatická segmentace ledvinových kamenů na medicínských snímcích	31
6.4.1	Řešení.....	31
6.4.2	Výsledky testování.....	31
6.5	Závěr.....	32
7	Analýza modelování ledvinových kamenů.....	33
7.1	Návrh matematického modelu LK.....	33
7.2	Analýza klinických ultrazvukových dat ledvin	34
7.3	Předzpracování obrazu.....	35
7.3.1	2D konvoluce.....	36
7.3.2	Mediánový filtr	36
7.3.3	Wienerův filtr	37
7.3.4	Prostorová filtrace a její cíle – klinická data	37
7.3.5	Komparativní analýza mediánového a Wienerova filtru.....	39
7.4	Prahování a segmentace.....	42
7.4.1	Analýza binarizace obrazu na základě prahování	42
7.4.2	Multiregionální segmentace – OTSU prahování	46
7.4.3	Algoritmus pro multiregionální segmentaci	47
7.5	Aktivní kontury	49
7.6	Testování navrženého modelu na reálných klinických datech	51
8	Závěr	59
9	Použitá literatura a internetové zdroje	60
	Přílohy.....	62
I.	Výsledky regionální segmentace.....	62
II.	Výsledky finálních modelů	66

Seznam zkratek a symbolů

lat ... latinsky
např ... například
ADH ... antidiuretický hormon
CT ... výpočetní tomografie
kHz, GHz ... kilo herz, giga herz
 n_{12} ... index lomu
 α ... úhel dopadu
 β ... úhel lomu
 v_1, v_2 ... rychlost šíření vlnění v daných prostředích
RTG ... rentgen
UZV ... ultrazvuk
MRI ... magnetická rezonance
DP ... diplomová práce
3D ... trojrozměrný
 ∇ ... gradient
 ∂ ... parciální derivace
R ... red (červená složka spektra)
G ... green (zelená složka spektra)
B ... blue (modrá složka spektra)
ROI ... oblast zájmu
LK ... ledvinový kámen
 W_b ... váha pozadí
 μ_b ... průměrná hodnota intenzity pozadí
 W_f ... váha popředí
 μ_f ... průměrná hodnota intenzity popředí
L ... pixely snímku různých odstínů šedi
 n_i ... počet pixelů daného odstínu šedi
N ... celkový počet pixelů
k ... prahovací úroveň
b ... pixely pozadí
f ... pixely popředí
 E_{int} ... interní energie
 E_{ext} ... externí energie
 E_{image} ... energie vypočítána z obrazu
 E_{con} ... body inicializační křivky

Seznam obrázků

Obrázek 1: Anatomická stavba ledviny	14
Obrázek 2: Nefron	14
Obrázek 3: Stavba nefronu	15
Obrázek 4: Ledvinové kameny	16
Obrázek 5: Ledvinové kameny	17
Obrázek 6: Frekvenční pásmo ultrazvukového vlnění	18
Obrázek 7: Odraz a lom ultrazvukového vlnění o rozhraní s rozdílným akustickým odporem	18
Obrázek 8: Ultrazvukové sondy	20
Obrázek 9: Reálný příklad ultrazvukových sond	20
Obrázek 10: Zobrazení A mód	21
Obrázek 11: Zobrazení v B módu – dnes nejčastější – ledvina	21
Obrázek 12: Zobrazení pomocí M módu	22
Obrázek 13: Dopplerovské zobrazování – ultrazvukový snímek ledviny	22
Obrázek 14: Histogram, a) jeden práh, b) více úrovní prahování	23
Obrázek 15: Segmentace pomocí prahování – aplikace na reálná klinická data	24
Obrázek 16: Segmentace využívající 5 úrovní prahování – aplikace na klinická data	24
Obrázek 17: Průběh funkce $g(x)$ a jejích derivací	25
Obrázek 18: Aktivní kontury	26
Obrázek 19: Předzpracování obrazu	28
Obrázek 20: Algoritmus pro detekci LK z CT snímků	29
Obrázek 21: Aplikace level set segmentace na CT snímek	29
Obrázek 22: Příklady klinických dat UZV snímků	30
Obrázek 23: Blokový diagram postupu	30
Obrázek 24: Předzpracování obrazu	31
Obrázek 25: Příklad snímků ze studie	32
Obrázek 26: Vývojový diagram – dosažení modelu LK	33
Obrázek 27: Klinická data	34
Obrázek 28: Klinická data	35
Obrázek 29: Klinická data	35
Obrázek 30: Princip konvoluce	36
Obrázek 31: Princip mediánového filtru	36
Obrázek 32: Aplikace mediánového filtru na reálných klinických datech	37
Obrázek 33: Aplikace Wienerova filtru na reálných klinických datech	37
Obrázek 34: Použití mediánového filtru	38
Obrázek 35: Použití Wienerova filtru	38
Obrázek 36: Princip binarizace obrazu	43
Obrázek 37: Binarizace obrazu	43
Obrázek 38: Binarizace obrazu	43
Obrázek 39: Binarizace obrazu	44
Obrázek 40: Prahování na základě vypočteného prahu – první snímek	44
Obrázek 41: Prahování na základě vypočteného prahu – druhý snímek	45
Obrázek 42: Segmentace na základě stupňů šedi jednotlivých pixelů	45
Obrázek 43: Segmentace na základě stupňů šedi jednotlivých pixelů	46

Obrázek 44: Princip multiregionální segmentace	47
Obrázek 45: Princip extrakce příslušné segmentační třídy v rámci multiregionální segmentace.....	47
Obrázek 46: Implementace algoritmu pro multiregionální segmentaci	48
Obrázek 47: Multiregionální segmentace – 2 prahové hodnoty	48
Obrázek 48: Multiregionální segmentace – 3 prahové hodnoty	48
Obrázek 49: Multiregionální segmentace – 4 prahové hodnoty	48
Obrázek 50: Multiregionální segmentace – 5 prahových hodnot	49
Obrázek 51: Aktivní kontury	49
Obrázek 52: Interaktivní zvolení oblasti ledvinového kamene.....	50
Obrázek 53: Aktivní kontury – inicializační křivka (modře), aktivní kontura (červeně).....	50
Obrázek 54: Aktivní kontury – přiblížení	51
Obrázek 55 Aktivní kontury – inicializační křivka (modře) a aktivní kontura (červeně)	51
Obrázek 56 Aktivní kontury – přiblížení	51
Obrázek 57: Snímek číslo 2 – data set 1	52
Obrázek 58: Snímek číslo 4 – data set 1	52
Obrázek 59: Snímek číslo 5 – data set 1	53
Obrázek 60: Snímek číslo 16 – data set 1	53
Obrázek 61: Snímek číslo 18 – data set 1	54
Obrázek 62: Snímek číslo 1 – data set 2	54
Obrázek 63: Snímek číslo 7 – data set 2	55
Obrázek 64: Snímek číslo 9 – data set 2	55

Seznam grafů

Graf 1: Hodnoty parametru BRISQUE v přehledném grafu – snímky z datasetu 1	40
Graf 2: Hodnoty parametru BRISQUE v přehledném grafu – snímky z datasetu 2	40
Graf 3: Hodnoty parametru NIQE v přehledném grafu – snímky z datasetu 1	41
Graf 4: Hodnoty parametru NIQE v přehledném grafu – snímky z datasetu 2	42
Graf 5: Srovnání referenčního modelu s navrženým modelem	56
Graf 6: Rozdíl [%] mezi navrženým modelem a referenčními hodnotami	57

Seznam tabulek

Tabulka 1: Vypočtené hodnoty parametru BRISQUE pro mediánový filtr a Wienerův filtr	39
Tabulka 2: Vypočtené hodnoty parametru NIQE pro mediánový filtr a Wienerův filtr	41
Tabulka 3: Srovnání referenčního modelu s navrženým modelem LK.....	56
Tabulka 4: Extrahované vlastnosti modelu LK	58

1 Úvod

Ledvinové kameny (urolitíaza) jsou v dnešní době stále častějším onemocněním. Nejčastěji postihuje lidi právě v produktivním věku života. Toto onemocnění probíhá naprosto individuálně – může probíhat bezpříznakově, ale také může vyústit až v ledvinovou koliku. V dnešní době je pro diagnostiku využíváno především ultrazvukového zobrazování, jelikož nezatěžuje organismus žádným typem záření a není nutná příprava před samotným vyšetřením.

Diplomová práce je zaměřena na problematiku ledvinových kamenů obecně, fyziologii i patologii ledvin – především ledvinových kamenů, ale také na metody, které se pro diagnostiku onemocnění využívají a jejich principy – v tomto případě jde hlavně o ultrazvukovou sonografii.

Cílem diplomové práce je tedy předzpracování ultrazvukového snímku LK a jeho další zpracování pro vytvoření matematického modelu ledvinových kamenů na tomto snímku – samotný model slouží k lokalizaci a extrakci vybraných parametrů LK.

Důležitým aspektem pro zpracování práce byly především metody předzpracování a segmentace obrazu. V rámci předzpracování obrazu byla implementována především filtrace pomocí mediánového filtru, který byl v důsledku vyhodnocených parametrů (brisque, niqe) vhodnější než filtr Wienerův. Cílem filtrace je především eliminace šumu, který ultrazvukové snímky zatěžuje velice významně a zhoršuje jejich kvalitu pro následné zpracování.


Pro segmentaci obrazu byla využita binarizace, jejíž účelem je odlišení objektů zájmu od okolních struktur. Binarizace byla provedena s využitím tzv. prahování – bylo otestováno prahování s jednou prahovou hodnotou, ale také s větším počtem prahových hodnot. Prahování s jednou prahovou hodnotou rozčleňuje obraz do dvou regionů – pixely, jejichž hodnota jsou nabývá úrovně větší než je hodnota prahu, jsou vykresleny jako logická 1 a pixely, jejichž hodnota jsou nabývá úrovně menší než je hodnota prahu, jsou vykresleny jako logická 0. V rámci segmentace s větším počtem prahových hodnot je snímek rozčleněn do více regionů (záleží na počtu zvolených prahových hodnot) a dále je extrahována pouze oblast, ve které se vyskytuje objekt zájmu (ledvinový kámen).

Po segmentaci prahováním následovala segmentace využívající aktivních kontur, jelikož i po aplikaci víceúrovňové segmentace na snímcích byly zobrazovány okolní struktury, které nabývaly jasových hodnot podobných jako ledvinové kameny. Tyto struktury byly eliminovány právě použitím aktivních kontur.

V samotném závěru práce bylo vyhodnocení extrahovaných vlastností navrženého modelu (jednalo se o srovnání plochy ledvinových kamenů na dosaženém modelu vůči tzv. zlatému standardu), obvod objektů zájmu a délky hlavní a vedlejší poloosy.

2 Anatomie a fyziologie ledvin

Ledviny spolu s močovými cestami tvoří vylučovací soustavu. Ledviny (lat. ren) jsou párovým orgánem uloženým v okolí bederní páteře. [1]




Obrázek 1: Anatomická stavba ledviny [1]

1. Vazivové pouzdro, 2. Ledvinná kůra, 3. Dřeň ledviny, 4. Papila ledviny, 5. Ledvinné kalichy, 6. Ledvinná tepna, 7. Ledvinná žíla, 8. Pánvička ledviny, 9. Močovod.

Na povrchu ledviny se nachází vazivové pouzdro, které chrání ledvinu. Pod ním je ledvinná kůra a hlouběji se nachází dřeň ledviny – zde jsou umístěny pyramidy, které jsou uloženy svou bází směrem k jejím okrajům. Směrem k ledvinné pánvičce je natočen hrot těchto pyramid.

Z ledvinné branky vystupuje *vena renalis* – ledvinová žíla, která slouží pro odvod neokysličené krve a nežádoucích látek. Touto pánvičkou naopak vstupuje *arteria renalis* – ledvinová tepna, která přivádí okysličenou krev a živiny. [1]



Obrázek 2: Nefron [1]


1. přívodná tepénka, 2. odvodná tepénka, 3. cévní klubičko, 4. vnitřní list Bowmanova pouzdra, 5. zevní list Bowmanova pouzdra, 6. proximální kanálek.

Funkční jednotkou ledviny je nefron (viz Obrázek 2). Je tvořen ledvinovými tělisky – základem každého z nich je cévní klubičko (glomerulus), jehož cévní zásobení je zajišťováno přívodnou a odvodnou tepénkou. Toto klubičko je uloženo v Bowmanově váčku, který je tvořen dvěma listy – vnitřní (těsně přiléhá ke glomerulu) a zevní. Mezi těmito listy se filtruje primární moč (zhruba 180 l). Dále postupuje do odvodného ledvinového kanálku, který má tři části:

- proximální kanálek,
- Henleova klička,
- distální kanálek – ústí až do sběrného kanálku.

Všechny výše zmíněné části ústí až do ductus papillaris, který vyúsťuje na ledvinových papilách.

Důležitou funkcí ledvin je nepochybně také produkce hormonů, konkrétně reninu (významně se podílí na zvyšování krevního tlaku) a erythropoetinu (významně ovlivňuje tvorbu krve). [1]



Obrázek 3: Stavba nefronu [1]

1. přívodná tepénka, 2. odvodná tepénka, 3. nefron, 4. Bowmanovo pouzdro, 5. proximální kanálek, 6. Henleova klička, 7. distální kanálek, 8. sběrný kanálek, 9. odvodný kanálek.

Hlavní funkcí ledvin je ovšem udržování stálosti vnitřního prostředí organismu. Vnitřním prostředím organismu rozumíme extracelulární tekutinu – je to tekutina vně buňky (obklopuje ji) a jejím úkolem je nejen zajistit přísun potřebných látek pro její správnou funkci, ale také zajistit odvod látek škodlivých a nadbytečných – jedná se především o odstraňování dusíkatých zplodin jako je např.: močovina, amoniak, kreatinin, ale také léčiva a další toxické látky.

Další nezbytnou funkcí ledvin je jejich vyrovnávací činnost. V průběhu dne množství vody a rozpuštěných látek v organismu značně kolísá a je úkolem ledvin tyto změny regulovat. V případě zvýšeného množství extracelulární tekutiny, dochází k většímu množství vyloučené moči s různým množstvím vyloučených látek z organismu, tzn. v případě zvýšeného množství extracelulární tekutiny, stoupá také diuréza, což je množství vyloučené moči za 24 hodin (běžně se hodnota diurézy pohybuje okolo 1,5 l). Na tomto se významně podílí antidiuretický hormon (ADH) a mineralokortikoidy. [1]

3 Patologie močového ústrojí – onemocnění ledvin


Onemocnění ledvin se v dnešní době objevuje celá řada – vývojové poruchy ledvin, insuficience ledvin, nefritický a nefrotický syndrom, záněty glomerulu a ledvinné pánvičky nebo nádory ledvin. [2] Předmětem této práce jsou však ledvinové kameny a jejich segmentace v ultrazvukových snímcích a proto je i tato kapitola zaměřena především na ně.

3.1 Urolitiáza – onemocnění močovými kameny

Ledvinové (močové) kameny vznikají v důsledku přítomnosti určité látky v močových cestách a to buď přímo v ledvinných kalíšcích a odtud se dále šíří močovými cestami, nebo způsobují obtíže přímo v místě vzniku – proto rozlišujeme dva druhy konkrementů:

- konkrementy větších rozměrů, které setrvávají přímo v ledvinné pánvičce – *pyelolitiáza*,
- nebo jsou to konkrementy menší, které odcházejí močovými cestami – *ureterolitiáza*.

Nejčastěji se jedná o minerální látky (konkrementy, kaménky), které jsou v moči hodně koncentrované a mají tendenci vytvářet krystalky. [8]



Obrázek 4: Ledvinové kameny [8]

Vlevo: ledvina postižena ledvinovými kameny (nephrolithiasis) – umístění konkrementů v papile a v druhém případě se konkrement dostal do močovodu, vpravo: zdravá ledvina bez konkrementů

Pravděpodobnost onemocnění ledvinovými kameny je pro každého člověka zhruba 10%. V případě výskytu tohoto onemocnění a odstranění obtíží je však 70 % šance, že se ledvinové kaménky vytvoří znovu (nejčastěji se vytvářejí v produktivním věku člověka). [1 7]

Přesná příčina vzniku tohoto onemocnění není však do dnes zcela objasněna, nicméně je uváděno mnoho faktorů, které mohou riziko vzniku zvýšit. Mezi tyto faktory patří především:

- nedostatečný pitný režim,
- nezdravá strava,
- časté infekce močových cest či kyselější pH moči,
- dědičné faktory,
- v neposlední řadě může být vznik ledvinových kamenů ovlivněn užíváním některých druhů léků.

Príznaky onemocnění jsou zcela specifické u jednotlivců – může probíhat bezpříznakově či naopak mohou obtíže vyústit až v ledvinovou koliku.

Při diagnóze je důležitá rodinná anamnéza, ale nezbytné je vyšetření krve i moči. Nejčastěji se k prokázání přítomnosti kaménků využívají zobrazovací metody – ultrazvuk a CT. [9]

Na ultrazvukovém vyšetření jsou kaménky občas velice obtížně rozpoznatelné, avšak jsou-li lokalizovány, lze změřit i jejich velikost. Jestliže se konkrement dostane do močovodu, je téměř nemožné jej odhalit pomocí ultrazvukového vyšetření. [8 10]

Podle složení jsou nejčastěji rozlišovány tyto typy močových kamenů:

- kalciové,
- urátové,
- struvitové,
- cystinové (vzácné).



Obrázek 5: Ledvinové kameny [10]

3.2 Vyšetřovací metody a diagnostika ledvinových kamenů

Velice často jsou ledvinové kameny u pacientů objeveny náhodně při jiném vyšetření – nejčastěji při ultrazvukovém vyšetření či při vyšetření rentgenem.

Kalciové ledvinové kameny je možné zobrazit prostým rentgenovým vyšetřením. Při jiných typech ledvinových kamenů je využíváno kontrastní látky. Nejčastěji je však pro zobrazování nebo detekci ledvinových kamenů a měření jejich velikosti využíváno ultrazvukového vyšetření.

Ve většině případů je možné vyhnout se vzniku močových kamenů zvýšeným pitným režimem či správnými dietními opatřeními. Některé druhy ledvinových kamenů lze rozpustit – jedná se o cystinové a urátové. Kameny, které způsobují další infekce v močových cestách, je nutné odstranit a k tomuto je využíváno několika druhů metod – nejčastěji je to řešeno endoskopicky nebo aplikací rázové vlny (kameny jsou rozdrceny na malé části a poté přirozeně vyjdou z močového ústrojí). [10]


Primárně se pro diagnostiku ledvinových kamenů využívá ultrazvukového vyšetření, jelikož má mnoho výhod – v podstatě nezatěžuje organismus a nepůsobí nepříznivě na vyšetřované tkáně ani jejich okolí.

4 Ultrazvukové vlnění a jeho využití v medicíně

Jak již bylo zmíněno v předchozí kapitole (viz kapitola 3.2), velice často je pro zobrazování ledvinových kamenů využíváno právě ultrazvukového vlnění, jelikož pro pacienty nepředstavuje téměř žádnou zátěž organismu. V následujících podkapitolách bude představeno blíže ultrazvukové vlnění s jeho fyzikálním principem a posléze také jeho využití v medicíně – zobrazovacích metodách.

4.1 Ultrazvukové vlnění – fyzikální princip

Ultrazvukové vlnění je vlněním mechanickým, jehož frekvence se pohybuje v rozmezí 20 kHz až do 1GHz. Ultrazvuk se šíří všemi třemi typy prostředí – plynným, kapalným i pevným – a to rozkmitáváním jednotlivých částic, které svou energii předávají částicím v jejich těsném okolí. Tím se šíří vlna dále do prostoru. [3]




Obrázek 6: Frekvenční pásmo ultrazvukového vlnění [11]

Rozlišujeme dva typy vlnění – příčné a podélné. Zatímco v kapalných a plynných prostředích se šíří pouze vlnění podélné, v pevných látkách se také šíří vlnění příčné.

4.1.1 Odraz a lom ultrazvukového vlnění

K odrazu či lomu ultrazvukového vlnění dochází v případě, že vlnění dopadne na rozhraní dvou prostředí, které se liší akustickým odporem – část vlnění je od rozhraní odražena zpět a část rozhraním prochází pod určitým úhlem (viz Obrázek 7).



Obrázek 7: Odraz a lom ultrazvukového vlnění o rozhraní s rozdílným akustickým odporem [12]

Rozlišujeme dva možné druhy lomu. Jedná se buďto o lom ke kolmici či lom od kolmice. V případě, že je hustota prostředí, ze kterého se vlnění šíří, větší než hustota prostředí, do kterého se vlnění láme, jedná se o lom od kolmice ($\alpha < \beta$). V opačném případě se jedná o lom ke kolmici ($\alpha > \beta$). [3 12]

Matematicky je pak možné tuto situaci popsat následující rovnicí:

$$n_{12} = \frac{\sin \alpha}{\sin \beta} = \frac{v_1}{v_2} \quad (1)$$

kde:

n_{12} ... index lomu [-]

α ... úhel dopadu [°]

β ... úhel lomu [°]

v_1, v_2 ... rychlost šíření vlnění v daných prostředích [m/s]

4.2 Ultrazvuková sonografie

Pro medicínské účely je využíváno ultrazvukového vlnění o frekvenci 1 – 20 MHz (bylo prokázáno, že tato intenzita nevyvolává u lidského organismu žádné podstatné změny – intenzita dosahuje maximální hodnoty $0,1 \text{ W} \cdot \text{cm}^{-2}$). [3]

Ultrazvukového vlnění je nejčastěji využíváno pro zobrazování anatomických struktur měkkých tkání lidského těla. Je využívána v oblastech urologie, angiografie, porodnictví a mnoha dalších. Zobrazování pomocí ultrazvuku má nespočet výhod, např.: nevyužívá škodlivého záření jako při vyšetřování pomocí RTG techniky, ultrazvuk je tedy bezpečný a neinvazivní, není nutná speciální příprava pacienta před vyšetřením, vyšetření samotné není příliš nákladné (ekonomicky).

Pomocí ultrazvukové sonografie je možné měkké tkáně nejen zobrazovat v reálném čase (k tomuto slouží módy A, B a 3D), ale také měřit velikost anatomických struktur, jejich vzdálenosti mezi sebou, hodnotit jejich složení, hodnotit vlastnosti krevního řečiště a mnoho dalšího. [3]


Používá se k diagnostice příčin bolesti, otoků a infekcí ve vnitřních orgánech těla, vyšetření dítěte u těhotných žen či mozku a boků u kojenců. Používá se také jako pomůcka pro vedení biopsií, diagnostiku srdečních chorob a pro posouzení poškození po infarktu.

Základní princip, který je při ultrazvukové sonografii využíván, pracuje na principu reflexní metody – při této metodě je vyslán impuls ke tkáni a podle její struktury je odražen zpět. V tomto případě sonda pracuje v režimu vysílače, ale také přijímače této vlny – sonda zde pracuje v impulzním režimu, tzn., jakmile je impuls vyslán ke tkáni, sonda se přepne do režimu přijetí a echo odražené od tkáně zaznamená. [3 7]

Ultrazvukové zobrazování, také nazývané ultrazvukové skenování nebo sonografie, zahrnuje použití snímače – sondy a ultrazvukového gelu umístěného přímo na kůži. Vysokofrekvenční zvukové vlny se přenášejí ze sondy přes gel do těla. Převodník shromažďuje zvuky, které se odrazí, a počítač poté použije tyto zvukové vlny k vytvoření obrazu. Vzhledem k tomu, že ultrazvukové snímky jsou zachyceny v reálném čase, mohou zobrazit strukturu a pohyb vnitřních orgánů těla, stejně jako krev protékající krevními cévami. [3]

4.3 Ultrazvukové snímače – sondy

V medicíně se jako zdroj ultrazvukového vlnění využívá soustava ultrazvukových měničů, které jsou umístěny přímo v sondě. V dnešní moderní medicíně je využíváno široké spektrum takovýchto sond – liší se od sebe především tvarem a pracovní frekvencí. Tvar sondy je ovlivněn především její aplikací, tzn.: jiný tvar bude mít sonda pro obecné účely a jiné sonda využívána v kardiologii či porodnictví. Co se týče pracovní frekvence, je nutné se řídit především faktem, že s rostoucí frekvencí ultrazvukového vlnění klesá hloubka průniku (s rostoucí pracovní frekvencí nejsme schopni zobrazovat hlouběji uložené tkáně lidského těla).



Obrázek 8: Ultrazvukové sondy [11]

Zleva: lineární, konvexní, sektorová sonda.

Ultrazvukové sondy je možné v dnešní medicíně rozdělit do dvou skupin. První jsou sondy s postupně buzenými měniči a druhou sondy s fázově řízenými měniči. První skupina je mnohem náročnější jak na rozměry, tak i konstrukčně a proto se v dnešní době do popředí dostávají především sondy druhé skupiny – s fázově řízenými měniči. [3]

4.3.1 Lineární sondy

Lineární sonda je typ sondy s postupně buzenými měniči. Výstupem je obraz obdélníkového tvaru. Je tvořena několika sty piezoelektrických elementů, které jsou uspořádány v jedné řadě. Postupným přepínáním jednotlivých měničů jsou měněny souřadnice UZV paprsku. Nevýhodou tohoto druhu sondy jsou relativně velké rozměry nutné pro konstrukci sondy. [3 11]



Obrázek 9: Reálný příklad ultrazvukových sond [17]

Zleva: sonda lineární, sonda sektorová, sonda konvexní

4.3.2 Sektorové sondy

V současné době se jedná o nejvyužívanější druh ultrazvukových sond. Měniče jsou uspořádány vedle sebe v krátké řadě. Měniče jsou buzeny současně, liší se pouze jejich fází. Sektorové sondy jsou stále dále vyvíjeny a zkoumány. [3 11]

4.3.3 Konvexní sondy


Měniče jsou uspořádány do vyklenuté řady, je možné říci, že se jedná o kombinaci dvou výše zmíněných typů sond – lineárního a sektorového.

4.4 Módy zobrazení

Pomocí ultrazvukové sonografie je možné zobrazování ve více módech. Jedná se o A mód, B mód, 3D zobrazování, M mód či o dopplerovské zobrazování. [3]

4.4.1 A mód

A mód je nejjednodušší formou zobrazování pomocí ultrazvukového vlnění. Jedná se o jednorozměrné zobrazování využívající amplitudu signálu (proto A mód z anglického amplitude mode). Výsledným obrazem z takového druhu zobrazení je jediná křivka, zobrazující právě zmíněnou amplitudu signálu na časové ose. V dnešní době je využíván spíš zřídka, jelikož je využíváno digitálního zpracování signálu – většina ultrazvukových sonografů však zobrazení v A módu stále umožňuje. [3]



Obrázek 10: Zobrazení A mód [3]

4.4.2 B mód

B mód vznikl z anglického brightness mode a jedná se o dvourozměrné zobrazení (v dnešní době je využíváno nejčastěji ze všech druhů UZV zobrazování). V sondě je uloženo několik měničů, jejichž echa jsou zaznamenávána tak, že jsme schopni vnímat obraz v reálném čase. [3 11]



Obrázek 11: Zobrazení v B módu – dnes nejčastější – ledvina


[zdroj: FN Ostrava, urologické oddělení]

4.4.3 Trojrozměrné zobrazení – 3D mód

Trojrozměrný obraz je vytvořen na základě série snímků dvourozměrného zobrazení, které jsou pak dále zpracovány. Nevýhodou takového snímku je náročnost na výpočetní výkon při jeho zpracování. V dnešní době není využíván tak hojně jako klasický B mód (nejčastěji používán pro zobrazení plodu v gynekologii).

4.4.4 M mód

M mód (z anglického motion mode) slouží ke sledování pohybu tkání v reálném čase. V podstatě se jedná o zobrazování dvourozměrné (podobně jako B mód). Nejčastěji je tento typ zobrazování využíván pro zobrazení činnosti srdce. Na x – ose je zobrazena změna polohy jednotlivých struktur a na y – ose je zobrazena změna pozice echa. [3 11]




Obrázek 12: Zobrazení pomocí M módu [19]

4.5 Dopplerovské zobrazování

Konvenční ultrazvuk zobrazuje snímky v tenkých plochých částech těla. Pokroky v ultrazvukové technologii zahrnují trojrozměrný (3D) ultrazvuk, který formuje data zvukové vlny na 3D obrazy.

Dopplerovská ultrazvuková studie může být součástí ultrazvukového vyšetření.

Dopplerovský ultrazvuk, nazývaný také barevná Dopplerovská ultrasonografie, je speciální ultrazvukovou technikou, která umožňuje lékařům sledovat a vyhodnocovat průtok krve tepnami a žilkami v břiše, pažích, nohou, krku nebo mozku (u kojenců a dětí), tělních orgánů, jako jsou játra nebo ledviny. [3]



Obrázek 13: Dopplerovské zobrazování – ultrazvukový snímek ledviny [13]

Existují tři typy dopplerovského ultrazvuku:

- *Barevný Doppler* používá počítač k převodu Dopplerových měření do řady barev, které ukazují rychlost a směr průtoku krve cévami.
- *Power Doppler* je novější technikou, která je citlivější než barevný Doppler a je schopná poskytnout větší detaily průtoku krve, zvláště když je průtok krve malý nebo minimální. Power Doppler však nepomáhá radiologovi určit směr průtoku krve, což může být v některých situacích důležité.
- *Spektrální Doppler* zobrazuje měření průtoku krve graficky, a to jako vzdálenost za jednotku času, než jako barevný obraz. Může také přeměňovat informace o průtoku krve do výrazného zvuku. [3]

5 Segmentační metody pro zpracování biomedicínských snímků

Segmentace snímků je složitý proces, kterému předchází především předzpracování obrazu – nejčastěji je v rámci tohoto předzpracování využíváno úprav kontrastu a jasu či filtrace obrazu různými druhy filtrů, např.: mediánový, které slouží k eliminaci šumu a jiných artefaktů.


Segmentace rozčleňuje snímek do několika menších regionů či objektů na základě vlastností jednotlivých pixelů. Cílem segmentace samotné je izolace objektů nebo regionu zájmu v daném snímku. Segmentace objektu na netriviálním snímku je jedním z nejsložitějších procesů v rámci zpracování obrazu vůbec.

Segmentační algoritmy pro monochromatické obrazy jsou obecně založeny na dvou základních parametrech intenzity pixelů – nespojitosti a podobnosti. V případě nespojitosti obrazu jde především o prudké změny hodnot jasu jednotlivých pixelů, jako jsou hrany na snímku. Naopak v případě podobnosti obrazu je snímek rozdělen do regionů, jehož pixely mají podobné vlastnosti a splňují tak zvolená přednastavená kritéria pro segmentaci určitého druhu objektu. [4 5]

5.1 Segmentace pomocí prahování


Prahování je jednou z nejjednodušších metod segmentace obrazu obecně. Řadí se také mezi metody nejrychlejší. V podstatě se jedná o jisté jasové odlišení objektů od pozadí v obraze – princip prahování spočívá ve zvolení vhodné mezní hodnoty (práhu – hodnoty jasu) tak, abychom vhodně oddělili objekty, které chceme segmentovat, od pozadí. Výsledkem je pak binární rozložení obrazu, které nabývá hodnot 1 a 0 (hodnotu 1 mají objekty, které oddělujeme a hodnotu 0 má pozadí obrazu). [6]

Je mnoho různých způsobů, kterými volíme hodnoty prahování – např.: stanovení práhu metodou nejmenší chyby, iterační proces u metody nejmenší chyby a prahování proměnným prahem. Nejčastěji se využívá metody prahování s proměnným prahem – obraz nemusí být dostatečně kontrastní na to, abychom pevně zvolili hodnotu práhu - u této metody si obraz rozdělíme do několika menších částí a pro každou tuto oblast se hodnota práhu vypočítá samostatně – vypočte se jako průměr maximální a minimální hodnoty jasu. [6]




Obrázek 14: Histogram, a) jeden práh, b) více úrovní prahování [16]

Osa y: počet pixelů dané jasové úrovně, osa x: jednotlivé jasové úrovně obsažené ve snímku.



Obrázek 15: Segmentace pomocí prahování – aplikace na reálná klinická data [zdroj snímku: FNO]
Prahová hodnota je stanovena na základě jasových hodnot pixelů na konkrétním snímku – v tomto případě je stanovena pouze jedna prahová hodnota. Vlevo: nativní snímek, vpravo: binarizovaný snímek.



Obrázek 16: Segmentace využívající 5 úrovní prahování – aplikace na klinická data [zdroj snímku: FNO]
A: Nativní snímek, B: multiregionální segmentace, C: extrakce ROI, D: extrakce LK

5.2 Segmentace pomocí detekce hran

V případě této metody jde především o hledání samotných hran v obraze (hrana v obraze je místo, kde se prudce mění intenzita pixelů). Skládá se ze dvou částí – první je hledání samotných hran v obraze a druhou je vytvoření segmentace a nalezení hran vzniklých segmentů. Rozeznat hranu na snímku však není nikterak jednoduché, např.: je-li obraz výrazně zašuměn, může být náročnější rozpoznat, zda se jedná o hranu nebo pouze o změnu intenzity ve snímku v důsledku narušení šumem. Proto jsou využívány filtry pro odstranění šumu (např.: Gaussův, mediánový, apod.).

Metody dále rozlišujeme na metody první a druhé derivace. Zatímco metody první derivace považují hranu za místo největší intenzity a ostatní okolí v obraze (homogenní) nabývá první derivace nulových hodnot, metody druhé derivace se využívají pouze pro určení místa, kde se hrana nachází (není znám směr, ani velikost hrany). Při výpočtu právě druhé derivace se hrana nachází v místě, kde derivace prochází nulovou hodnotou. [18]

5.2.1 Metody první derivace

Metody první derivace jsou také označovány jako metody gradientní. Jsou-li provedeny parciální derivace snímku jak podle x , tak podle y , je získán vektor udávající směr a velikost gradientu. Gradient je kolmý vektor k vektoru, který udává směr hrany. Ze vzorců níže je možné dopočítat také délku hrany či úhel, který hrana svírá s osou x . [18]

$$|\nabla g(i, j)| = \sqrt{\left(\frac{\partial g}{\partial x}\right)^2 + \left(\frac{\partial g}{\partial y}\right)^2} \quad (2)$$

$$\varphi = \arctg\left(\frac{\frac{\partial g}{\partial y}}{\frac{\partial g}{\partial x}}\right) \quad (3)$$

Používanější metodou při výpočtu první derivace je využíváno hranových operátorů – konvoluční matice. Je-li provedena konvoluce snímků s tímto hranovým operátorem je nalezena hledaná složka gradientu. Hranových operátorů je celá řada, např.: Sobelův operátor, Prewittův operátor, Kirschův operátor, atp. [18]

Sobelův operátor:


$$g_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad g_y = \begin{bmatrix} -1 & 2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}$$

Prewittův operátor:

$$g_x = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix} \quad g_y = \begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix}$$

5.2.2 Metody druhé derivace

Metody založené na druhé derivaci využívají faktu, že v místě, kde je nejvyšší první derivace, druhá prochází nulovou hodnotou (viz Obrázek 17). [18]



Obrázek 17: Průběh funkce $g(x)$ a jejích derivací [18]

Vlevo: Průběh funkce $g(x)$, střed: první derivace funkce – nejvyšší hodnota funkce, vpravo: druhá derivace funkce – průchod nulovou hodnotou

Jsou opět dvě možnosti jak vypočíst hodnotu druhé derivace. První možností jsou opět rovnice. V případě této varianty je ovšem důležité určit zda je funkce diskrétní či nikoliv. Jedná-li se o diskrétní funkci, vypočteme druhou derivaci z rovnice:

$$\Delta^2 f(x) = \frac{(f(x+1) - f(x-1))}{h^2} + O(h^2) \quad (4)$$

V případě, že se nejedná o diskrétní funkci je druhá derivace vypočtena z následujícího vztahu:

$$\Delta g(x, y) = \frac{\partial^2 g(x, y)}{\partial x^2} + \frac{\partial^2 g(x, y)}{\partial y^2} \quad (5)$$

Druhou možností je opět využití některého z hranových operátorů, např.: Laplaceovy (je kladen důraz na středové body a součet všech prvků je vždy ve výsledku roven nule). [18]

5.2.3 Cannyho detektor

Cannyho detektor je možné označit za ideální hranový detektor. Je možné jej řadit mezi detektory využívající první derivace, jelikož je nutné znát jak velikost gradientu, tak jeho směr.

Cannyho detektor kombinuje vlastnosti, které stanovil v 80. letech J. F. Canny, jednalo se o požadavky, jaké by měl ideální detektor splňovat:

- minimální chyba detekce hran

- správná lokalizace
- jediná odezva.

Při použití Cannyho detektoru je nutné nejdříve vytvořit konvoluční matici Gaussova filtru, který je často využíván pro eliminaci šumu v obraze. Následně je obraz rozmazán ve směru osy y a je vypočítávána parciální derivace podle x. Toto se opakuje taktéž ve směru osy x a je vypočítána parciální derivace podle y. V závěru je možné vypočíst velikost gradientu, jelikož z předchozích kroků známe parciální derivace g_x a g_y ze vztahu: [18]

$$|g| = \sqrt{g_x^2 + g_y^2} \quad (6)$$

5.3 Segmentace pomocí aktivních kontur

Segmentace obrazu pomocí aktivních kontur je velice náročná. Jedná se o segmentaci, která je komplikovaná především kvůli přítomnosti šumu v obraze či artefaktů vzniklých při jeho pořizování. Principem je vyhledávání objektů zájmu na daném snímku, který má uzavřené hranice a je plynulý (homogenní). V obraze je definována křivka, která mění své vlastnosti na základě externích a interních energií v obraze (deformuje se, proto je tento druh segmentace řazen mezi deformovatelné modely). Externí energie je vypočítána na základě obrazu, ve kterém je umístěna a jejím cílem je přitažení křivky k lokálnímu minimu v obraze. Interní energii definuje křivka samotná a zajišťuje hladkost jejího průběhu. [6]

Rozlišujeme dva typy aktivních kontur:

- Parametrické – iniciační (počáteční) křivka je volena parametricky.
- Geometrické – iniciační křivka je volena implicitně.



Obrázek 18: Aktivní kontury

Modře inicializační kontura, červeně aktivní kontura, počet iterací: 1600

6 Metody segmentace ledvinových kamenů – rešeršní shrnutí nejnovějších poznatků

Jelikož je segmentačních metod celá řada, v této kapitole jsem shrnula nejnovější poznatky z odborné vědecké literatury k současnému stavu problematiky. Jaké segmentační metody se dnes nejčastěji využívají, jaký je postup předzpracování obrazu pro segmentaci, ale také jaké konkrétní metody jsou využívány právě pro segmentaci ultrazvukových snímků (a tedy i ledvinových kamenů).

6.1 Analýza a implementace detekce ledvinových kamenů metodou úrovně segmentace

Ultrazvukové zobrazování je jednou z nejdostupnějších technik využívaných pro diagnostiku ledvinových onemocnění, jako jsou ledvinové kameny, cysty, blokády či nádorové buňky.

Onemocnění ledvinovými kameny je jedním z nejčastějších onemocnění. V počáteční fázi probíhá často bez jakýchkoliv příznaků, což může vést až k poškození ledvin. Vzhledem k následným komplikacím je proto důležité objevit onemocnění co nejdříve. Proto je využíváno právě ultrazvukové sonografie, jelikož jde o neinvazivní metodu, která je taktéž dostupná i z finančního hlediska.

Nedostatečná funkce ledvin může být pro pacienta omezující, proto je důležité detekovat ledvinové kameny již v počátcích. Přesná identifikace LK je nezbytná pro následnou úspěšnou léčbu.

Detekce ledvinových kamenů je však velmi náročným procesem, jelikož jsou snímky zatíženy především šumem a nedostatečným kontrastem.

Vhodným způsobem pro detekci a lokalizaci ledvinových kamenů je např.: segmentace obrazu. [20]

6.1.1 Řešení


Základem při využívání segmentací obrazu je samozřejmě jeho předzpracování. Hlavním cílem takového preprocesingu je vylepšení kontrastu ultrazvukových snímků, které jsou nejvíce zatíženy šumem – konkrétně se jedná o „speckle“ šum (výstelkový šum). Bez předzpracování obrazu by tyto snímky zřejmě nebylo možné dále zpracovávat a použít je pro analýzu a následnou segmentaci. Při zákrocích pro odstraňování ledvinových kamenů je nezbytné správně lokalizovat tyto útvary, což je při redukci šumu a optimalizaci parametrů obrazu jako je právě kontrast, mnohem snadnější.

Kroky, které jsou v takovém předzpracování obrazu obsaženy:

- Rekonstrukce obrazu,
- vyhlazení obrazu a zvýraznění hran,
- vylepšení (optimalizace) kontrastu.

Rekonstrukcí obrazu je myšleno především zmírnění jeho nedokonalostí, které mohou být způsobeny mnoha faktory, např.: pohybem pacienta, šumem, apod. Především jsou způsobeny v průběhu vyšetření ultrazvukem.

Vyhlazení obrazu a zvýraznění hran je dalším krokem při předzpracování obrazu. V této fázi je rekonstruovaný obraz optimalizován v prostorové i frekvenční doméně využitím Gaborova filtru. Tento filtr se chová jako filtr typu pásmová propust. Vyhlazení obrazu a odstranění šumu je poté provedeno využitím operátoru konvoluce. [20]



Obrázek 19: Předzpracování obrazu [20 upraveno]

Pro *vylepšení kontrastu* je využíváno histogramu, na kterém jsou zřetelné intenzity obsažené v obraze. Ekvalizace pomocí histogramu je využívána právě pro dosažení optimálních výsledků v rámci kontrastu. Je možné toto provádět na snímku jako celku nebo po jednotlivých částech v obraze. [20]


6.2 Detekce ledvinových kamenů na CT snímcích

Zobrazování v dnešní době patří mezi stěžejní metody pro diagnostiku nejrůznější typů patologií. Také má obrovský význam pro biomedicínské a klinické výzkumy.

Ledviny jsou párovým orgánem uloženým v retroperitoneálním prostoru. Jejich hlavní funkcí je odvádění odpadních a škodlivých látek z organismu. Existuje mnoho patologií, které ledviny postihují, např.: infekce, diabetická nefropatie, ale v dnešní době se často vyskytuje onemocnění ledvinovými kameny. [21]

6.2.1 Řešení

Navržená metoda se zabývá segmentací ledvinových kamenů ze snímků CT – umožňuje identifikaci ledvinového kamene, ale také měřit jeho velikost, plochu a lokalizovat jej. Metoda je založena na 3 krocích – předzpracování obrazu, level set segmentace a samotná analýza LK (viz Obrázek 20). [21]



Obrázek 20: Algoritmus pro detekci LK z CT snímků [21 upraveno]

Po načtení snímku následuje proces předzpracování obrazu, který je pro další vyhodnocení velice důležitý. Nejdříve je nutné extrahovat ze snímku pouze oblast zájmu a poté byl snímek převeden do odstínů šedi. [21]

Pro segmentaci snímků byla použita metoda level set. Tato metoda závisí na dvou parametrech a to na pozici a čase. Pro jakýkoliv snímek je možné vytvořit level set funkci $\Phi(a,b)$ popisující konturu. Kontura D je definována nulovou funkcí level set:

$$D = \{(a,b) | \Phi(a,b) = 0\}$$

Uvnitř a vně regionu je křivka popsána spojitou funkcí Φ pomocí následujících rovnic:

$$\Phi(a,b) > 0 \dots \text{Uvnitř kontury}$$

$$\Phi(a,b) = 0 \dots \text{v místě kontury}$$

$$\Phi(a,b) < 0 \dots \text{vně kontury.}$$

Následuje samotná identifikace LK, která závisí především na výsledku segmentační metody – zda je či není ledvinový kámen identifikován. V případě, že je kámen na snímku zaznamenán dojde k výpočtu požadovaných parametrů modelu. [21]

6.2.2 Výsledky testování

Algoritmus byl implementován v MATLABu 2015b. vyhodnocení proběhlo na 50 snímcích pacientů. V rámci předzpracování je z načtených snímků extrahována oblast zájmu pro umožnění přesnější segmentace. Následně byla aplikována metoda level set segmentace.




Obrázek 21: Aplikace level set segmentace na CT snímek [21]

Vlevo: oblast zájmu – LK, vpravo: identifikace kamenů na CT snímku.

6.3 Diagnostika ledvinových kamenů na UZV snímcích

Ultrazvuková sonografie je s jistotou nejčastěji využívána modalita pro zobrazování ledvinových kamenů především proto, že nezatěžuje pacientův organismus. Na druhou stranu se jedná o metodu, která je nejvíce náchylná k šumu na snímcích. [22]

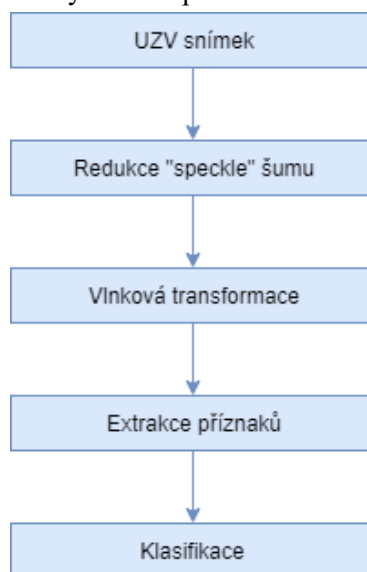


Obrázek 22: Příklady klinických dat UZV snímků [22]

6.3.1 Řešení

Vzhledem k obrovskému výskytu šumu na UZV snímcích je nezbytné snímky předzpracovat a tento šum odstranit. Nejčastějším druhem šumu zatěžující UZV snímky je speckle šum. Proto je tzv. „despeckling“ krokem, obsaženým v předzpracování.

V tomto článku je pro odstranění šumu využíváno prahování vlnkových koeficientů. [22]



Obrázek 23: Blokový diagram postupu [22 upraveno]

Speckle šum vzniká již při samotném vyšetření, kdy jsou snímky pořizovány, a to kvůli okolním tkáním v pozadí, tukovým tkáním či pohybům pacienta v důsledku dýchání, apod. Speckle šum velice významně ovlivňuje detekci léze ve snímku – kontrast je redukován při výskytu tohoto druhu šumu a léze může být obtížně detekovatelná, proto je důležité jej odstranit.

V případě vlnkového prahování jsou rozlišeny dva typy: tzv. soft a hard vlnkové prahování. Výhodnější je prahování jemnější tedy soft, jelikož nedochází k tak ostrým změnám jako v případě tvrdého prahování a i samotný obraz má větší kvalitu.


Vlnková transformace je matematická operace, která rozdělí souvislou vlnu do odlišných částí. Každá tato část může být popsána frekvenčním rozsahem. Využívá se především pro rozklad signálů na

jednotlivé složky, identifikaci okamžitých frekvencí, ale také pro odstraňování šumu či detekci nespojitostí signálu a jeho derivací. Vlnková transformace je ve své podstatě konvolucí určité vlny. [22]

6.3.2 Výsledky testování

Algoritmus byl implementován v MATLABu verze 7.14. Dataset se skládá z 19 ultrazvukových snímků ledvin bez výskytu ledvinových kamenů a 13 snímků ledvin, kde se ledvinové kameny vyskytují. Snímky byly pořízeny sondou o frekvenci 3.5MHz (vhodná pro zobrazování ledvin). Všechny snímky byly převedeny do jpeg formátu.

V rámci předzpracování obrazu bylo využito jemnější vlnkové transformace. [22]



Obrázek 24: Předzpracování obrazu [22]

Vlevo: nativní snímek, vpravo: snímek po aplikaci vlnkové transformace.

6.4 Automatická segmentace ledvinových kamenů na medicínských snímcích

Rozpoznávání objektů na snímcích je náročný proces. Proto byla navržena efektivnější metoda pro rozpoznání ledvinových kamenů v ultrazvukových snímcích.

Při ultrazvukovém zobrazování jsou do lidského těla vysílány impulzy pomocí ultrazvukové sondy, která je přiložena na kůži pacienta. Odražená echa těchto impulzů jsou poté zobrazeny jako výsledný snímek. [23]

6.4.1 Řešení

Rozpoznání ledvinového kamene na ultrazvukovém snímku je často velmi obtížné a to z důvodu přítomnosti šumu. Odlišit na snímku ledvinový kámen od speckle šumu je možné především na základě přítomnosti stínu, který se vyskytuje pouze u ledvinového kamene, nikoli u šumu.

Prvním krokem k úspěšné segmentaci kamene je předzpracování obrazu – nejčastěji jsou využívány různé druhy filtrací, aby byl zredukován šum – zde konkrétně byl aplikován mediánový filtr. Jelikož ledvinové kameny mají mnohem vyšší kontrast, než okolní struktury byl algoritmus pro segmentaci rozdělen do dvou fází.

V první fázi jsou všechny objekty, které mají vysokou jasovou hodnotu považovány za potenciální ledvinový kámen. V druhé fázi jsou tyto objekty posuzovány a pro vyhodnocení je klíčová právě přítomnost stínu na snímku – má-li objekt svůj stín, je označen jako ledvinový kámen. [23]

6.4.2 Výsledky testování

Pro tuto studii bylo použito 37 snímků pacientů různých věkových kategorií.



Obrázek 25: Příklad snímků ze studie [23]

Vlevo: nativní snímek, vpravo: segmentovaný ledvinový kámen.

Segmentace byla provedena na základě růstu regionu (pyramidal seeded region grow) a na základě algoritmu pro vyhodnocení ledvinového kamene (hledal se stín LK). [23]

6.5 Závěr

Na základě zpracování teoretické části diplomové práce a vyhledání relevantních článků je možné usoudit, že nejdůležitějším krokem pro segmentaci objektů ze snímku je již samotné předzpracování obrazu, čehož je dosaženo aplikací vhodně zvolených filtrů (často bývá aplikován filtr mediánový), úpravou kontrastu snímku a zvýraznění hran. V rámci segmentace je důležité oddělit objekt od pozadí vhodnými metodami na základě jasových hodnot pixelů, kterými se kámen liší od okolních struktur. V důsledku šumu je však možné, některé struktury vyhodnotit jako ledvinový kámen i přesto, že jím nejsou a proto je důležité posuzovat také stín objektu.

7 Analýza modelování ledvinových kamenů

Cílem praktické části diplomové práce je vytvoření matematického modelu ledvinových kamenů na ultrazvukových snímcích. Pro dosažení optimálních výsledků bylo důležité obraz nejprve předzpracovat – nejdůležitější částí samotného předzpracování byla filtrace pomocí mediánového a Wienerova filtru. Následně byla provedena komparativní analýza těchto dvou filtrů na základě dvou vybraných parametrů (brisque a niqe) a byl zvolen vhodnější, který byl použit pro další zpracování obrazu.

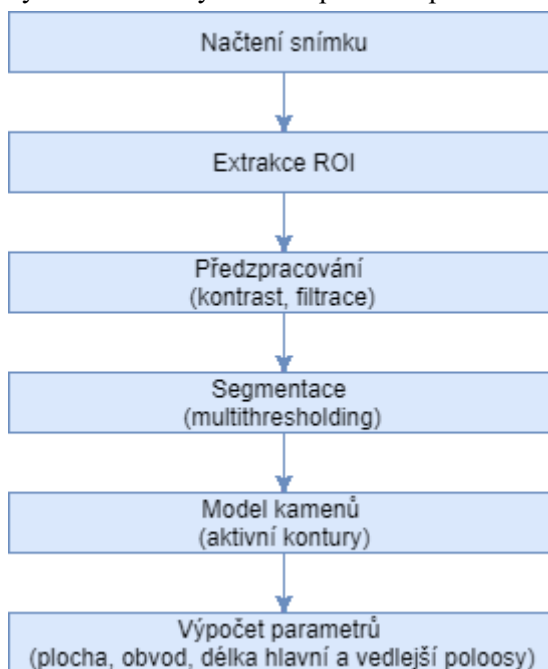
Dalším krokem byla samotná segmentace předzpracovaného snímku, aby bylo možné vytvořit model LK. Segmentace je zjednodušeně odlišení objektu zájmu od okolních struktur. V rámci segmentace v této DP bylo využito prahování (binarizace obrazu na základě zvoleného prahu) a následně otestováno prahování s jednou i větším počtem prahovacích úrovní, které odlišují objektu na základě jasových hodnot jednotlivých pixelů v obraze.

Jelikož se na snímcích vyskytují také struktury, které mají podobné jasové vlastnosti jako ledvinové kameny, bylo nutné po segmentaci prahováním aplikovat ještě segmentaci pomocí aktivních kontur, díky kterým došlo k eliminaci nežádoucích objektů v obraze.

Poslední částí diplomové práce byla extrakce vlastností modelu LK. Konkrétně se jednalo o obsah, obvod a délky hlavní a vedlejší poloosy. Plocha navrženého modelu byla vyhodnocena ve srovnání s plochou, která byla vypočtena na základě počtu bílých pixelů obsažených na snímku před aplikací aktivních kontur. Všechny parametry jsou uvedeny v tabulkách a srovnání v přehledných grafech.

7.1 Návrh matematického modelu LK

Prvním krokem pro realizaci praktické části diplomové práce bylo navrhnout metodu pro získání modelu ledvinových kamenů. Níže (viz Obrázek 26) je uveden vývojový diagram pro zjednodušení a představu postupu, jakým bylo dosaženo výsledků diplomové práce.



Obrázek 26: Vývojový diagram – dosažení modelu LK

Po načtení samotného snímku následuje extrakce ROI, tedy oblasti, ve které se nacházejí ledvinové kameny na ultrazvukovém snímku. Poté následuje předzpracování snímku.

V rámci předzpracování snímku bylo využito automatické úpravy kontrastu a následně došlo k otestování dvou typů filtrů – mediánového a Wienerova. Filtrace byla do algoritmu zařazena především kvůli eliminaci šumu na UZV snímcích a pro zlepšení jejich kvality pro další zpracování.

Dalším blokem v navrženém algoritmu je segmentace – ta byla provedena na základě prahování s větším počtem prahovacích hodnot – multiregionální segmentace. Snímek tak byl rozdělen na základě jasových hodnot pixelů do určitých tříd a následně byla extrahována pouze třída, ve které se nacházely ledvinové kameny.

Jelikož se na snímcích objevují struktury, které mají podobné jasové hodnoty jako objekty zájmu (LK), byla následně zvolena ještě segmentace pomocí aktivních kontur, kde došlo k eliminaci těchto struktur.

Posledním blokem je výpočet zvolených parametrů hotového modelu LK. Mezi tyto parametry patří plocha objektů zájmu, jejich obvod a délka hlavní/vedlejší poloosy.


Struktura algoritmu byla zvolena právě tímto způsobem především proto, aby bylo dosaženo co nejefektivnějšího předzpracování a následné segmentace obrazu, aby bylo možné ledvinové kameny na snímku co nejjednodušeji lokalizovat a zjistit výše zmíněné parametry.

Praktická část byla realizována v programu MATLAB.

7.2 Analýza klinických ultrazvukových dat ledvin

Veškeré snímky pro tuto DP byly poskytnuty MUDr. Veronikou Hájkovou z urologického oddělení Fakultní nemocnice v Ostravě.


Snímky byly poskytnuty ve dvou data setech – celkově 30 snímků. V prvním data setu je snímků 18, ve druhém 12.



Obrázek 27: Klinická data [urologická klinika FNO]


Vlevo: snímek z prvního data setu (zeleně označen objekt zájmu - ledvinový kámen), vpravo: snímek z druhého data setu – ledvinový kámen je velice obtížné rozpoznat.

Celkově bylo z těchto data setů použito 18 snímků a tyto byly dále vyhodnoceny. Kvalita a rozlišení zbylých snímků byl pro další zpracování a vyhodnocování nedostatečná (viz Obrázek 27).



Obrázek 28: Klinická data [urologická klinika FNO]

Vlevo: snímek z prvního data setu (zeleně označen objekt zájmu - ledvinový kámen), vpravo: snímek z druhého data setu.



Obrázek 29: Klinická data [urologická klinika FNO]

Vlevo: snímek z prvního data setu (zeleně označen objekt zájmu - ledvinový kámen), vpravo: snímek z druhého data setu.

7.3 Předzpracování obrazu


Jak z teoretické části (i všech dostupných zdrojů pro segmentace obrazu) vyplývá, je základem pro správné odlišení objektu zájmu především vhodně zvolená příprava obrazu, tedy jeho předzpracování. V rámci této diplomové práce byly vyzkoušeny různé metody tohoto předzpracování a dle výsledků je zřejmé, že ne všechny byly vhodné. Níže bude postupně vypsán postup, který byl při předzpracování proveden.

Prvním krokem pro zpracování obrazu v aplikaci bylo převedení snímku z klasického RGB formátu (i přesto, že se jedná o ultrazvukové snímky, jsou zde obsaženy pixely z RGB spektra) do formátu obsahujícího pouze odstíny šedi. Tohoto bylo dosaženo, již v MATLABu přednastaveným algoritmem, *rgb2gray()*. Ten převede snímek na základě poměru jednotlivých složek spektra dle následující rovnice níže:

$$0.2989 * R + 0.587 * G + 0.1140 * B \quad (7)$$

7.3.1 2D konvoluce

Konvoluce je základní matematickou operací, která se využívá při zpracování a filtrování obrazu. V podstatě se jedná o operaci, která ze dvou funkcí vytvoří jednu. Po obraze se přesouvá konvoluční matice a v každém pixelu obrazu je hodnota vynásobena a následně sečtena, čímž vzniká hodnota nová (viz Obrázek 30). [14]




Obrázek 30: Princip konvoluce [14]

Konvoluční matice může mít rozměry 3x3, 5x5, atp. Využívá se k nastavování vlastností filtrů. Vztah pro konvoluci je uveden níže:


$$f(x, y) * h(x, y) = \sum_{r=0}^{M-1} \sum_{s=0}^{N-1} f(r, s) * h(x - r, y - s) \quad (8)$$

7.3.2 Mediánový filtr

V případě mediánového filtru dochází k nahrazení původní hodnoty pixelu hodnotou, která je získána z výpočtu mediánu pro okolní body tohoto pixelu. Nejčastěji se využívá pro odstraňování šumu (dojde k vyhlazení obrazu). Principem je seřazení hodnot jasu jednotlivých pixelů v obraze od nejmenší po největší a je vybrána hodnota ležící přesně uprostřed (v případě, že je počet bodů sudý a uprostřed jsou dvě hodnoty, provádí se jejich průměr) a je dosazena na místo vypočítávaného pixelu. Nevýhodou použití tohoto druhu filtru je především ztráta informace a detailů v obraze. [14 16]



Obrázek 31: Princip mediánového filtru




Obrázek 32: Aplikace mediánového filtru na reálných klinických datech

Vlevo: nativní snímek, vpravo: aplikace filtrační matice 12x12.

7.3.3 Wienerův filtr

Wienerův filtr (pojmenovaný po N. Wienerovi, který jej poprvé zmínil v roce 1942) je jednou z nejznámějších metod pro největší přiblížení se lineární obnově (restore) obrazu. Principem Wienerova filtru je především získání detailů v obraze, který není často v příliš vysoké kvalitě (ovlivněný šumem, velmi často se jedná o snímky, které nemají příliš ostré hrany, atp...). [4]




Obrázek 33: Aplikace Wienerova filtru na reálných klinických datech

Vlevo: nativní snímek, vpravo: aplikace filtrační matice 12x12.

7.3.4 Prostorová filtrace a její cíle – klinická data

Nejdůležitější část při předzpracování obrazu tvoří samotná filtrace snímků. Ultrazvukové obrazy jsou velice zatíženy šumem (na rozdíl od snímků vzniklých při CT či MRI), a proto bylo nutné jej eliminovat. Dalším cílem filtrace bylo vyhlazení snímků pro jejich další použití.


V rámci diplomové práce bylo použito dvou typů filtrů – filtr mediánový a filtr Wienerův. Níže jsou uvedeny příklady použití filtrů na klinických datech. Nejdříve byl aplikován mediánový filtr (viz Obrázek 34) využívající filtrační matice (jádro) 6x6, 12x12 a 15x15.



Obrázek 34: Použití mediánového filtru

A: nativní snímek – oblast zájmu – ledvinový kámen, **B:** snímek po filtraci mediánovým filtrem s maticí 6x6, **C:** snímek po filtraci mediánovým filtrem s maticí 12x12, **D:** snímek po filtraci mediánovým filtrem s maticí 15x15.

Druhým filtrem, který byl při předzpracování aplikován, byl filtr Wienerův. Níže je příklad snímku filtrovaného taktéž s použitím filtrační matice 6x6, 12x12 a 15x15 (viz Obrázek 35).



Obrázek 35: Použití Wienerova filtru

A: nativní snímek – oblast zájmu – ledvinový kámen, **B:** snímek po filtraci Wienerovým filtrem s maticí 6x6, **C:** snímek po filtraci Wienerovým filtrem s maticí 12x12, **D:** snímek po filtraci Wienerovým filtrem s maticí 15x15.

7.3.5 Komparativní analýza mediánového a Wienerova filtru

Srovnání mezi aplikovanými filtry bylo provedeno na základě dvou parametrů, tzv. no-reference parametrů – neexistuje žádný referenční snímek, který by sloužil jako zlatý standard pro evaluaci příslušné metody. Konkrétně se jedná o parametr *Brisque* a *Niqe*.


Parametr brisque (Blind/Referenceless Image Spatial Quality Evaluator) vyhodnocuje kvalitu obrazu vůči modelu vypočteného ze snímků s podobným zkreslením jako posuzovaný snímek. V případě tohoto parametru však platí, že čím menší je hodnota vypočteného *score*, tím lepší kvalitu obraz má. Hodnoty parametru byly vypočteny pro oba filtry – tudíž mediánový i Wienerův a zaznamenány do tabulky (viz Tabulka 1) a grafech níže (viz Graf 1 a Graf 2). Pro přehlednost byly vytvořeny dva grafy pro tento parametr – každý graf obsahuje zobrazení a zaznamenání hodnot pro snímky ze stejného data setu.

Tabulka 1: Vypočtené hodnoty parametru BRISQUE pro mediánový filtr a Wienerův filtr

První sloupec udává číslo snímku z daného data setu – první část snímků označená kurzívou je z 1. data setu, druhá část je z 2. data setu (odděleno volným řádkem), čísla snímků odpovídají označení použitých snímků v poskytnutých klinických datech, proto nejsou seřazeny postupně.


	Medián			Wienerův			Medián - průměr	Wienerův - průměr
	6x6	12x12	15x15	6x6	12x12	15x15		
<i>2</i>	44.769	50.891	54.846	50.319	50.939	50.947	50.169	50.735
<i>4</i>	46.128	49.106	54.107	50.824	51.198	52.568	49.780	51.530
<i>5</i>	44.063	44.888	48.197	45.290	47.839	49.054	45.716	47.394
<i>6</i>	51.421	55.567	57.377	48.507	49.879	49.027	54.788	49.138
<i>9</i>	44.607	44.615	47.571	47.716	49.227	49.966	45.598	48.970
<i>10</i>	51.628	51.205	53.037	48.333	49.649	50.538	51.956	49.507
<i>11</i>	45.162	48.361	51.425	47.753	52.732	56.072	48.316	52.186
<i>13</i>	44.866	45.100	46.184	47.730	51.133	53.837	45.383	50.900
<i>14</i>	57.048	59.528	59.803	51.876	54.412	56.404	58.793	54.230
<i>16</i>	56.023	58.976	61.668	51.400	49.022	51.942	58.889	50.788
<i>18</i>	51.008	52.729	51.894	38.957	54.074	51.948	51.877	48.326
<i>1</i>	39.697	39.228	35.129	30.160	25.364	25.380	38.018	26.968
<i>2</i>	41.987	45.743	42.891	31.782	33.311	30.763	43.540	31.952
<i>7</i>	43.842	44.158	44.621	31.647	22.761	21.205	44.207	25.204
<i>8</i>	39.722	42.464	43.667	20.945	26.533	28.818	41.951	25.432
<i>9</i>	40.132	41.407	40.429	29.387	17.443	13.944	40.656	20.258
<i>10</i>	43.147	42.523	36.267	25.602	29.936	29.178	40.646	28.239
<i>11</i>	41.895	39.690	35.098	29.614	26.850	25.928	38.894	27.464

Na základě zmíněné tabulky i grafů je zřejmé, že pro snímky z prvního data setu je vhodnější pro předzpracování filtr mediánový. V případě snímků v druhém data setu je patrné, že nižší hodnoty (tedy vhodnější) vycházejí pro filtr Wienerův. Toto může být zapříčiněno špatnou kvalitou snímků v druhém data setu. Tyto skutečnosti jsou zřejmé v následujících grafech (viz Graf 1 a Graf 2).



Graf 1: Hodnoty parametru BRISQUE v přehledném grafu – snímky z datasetu 1

V grafu jsou uvedeny průměrné hodnoty pro oba testované filtry (v tabulce sloupec medián – průměr a Wienerův – průměr). Jedná se o průměr tří použitých filtračních matic – 6x6, 12x12, 15x15.




Graf 2: Hodnoty parametru BRISQUE v přehledném grafu – snímky z datasetu 2

V grafu jsou uvedeny průměrné hodnoty pro oba testované filtry (v tabulce sloupec medián – průměr a Wienerův – průměr). Jedná se o průměr tří použitých filtračních matic – 6x6, 12x12, 15x15.

Druhým vyhodnocovaným parametrem byl *nqe* (Naturalness Image Quality Evaluator), který vypočítává score vzhledem k výchozí hodnotě snímku. Taktéž platí, čím nižší hodnota při vyhodnocení, tím lepší kvality obrazu bylo dosaženo. Níže opět uvedena tabulka hodnot pro oba typy filtrů s různými maticemi a průměrná hodnota pro mediánový i Wienerův filtr (viz Tabulka 2).


Tabulka 2: Vypočtené hodnoty parametru NIQE pro mediánový filtr a Wienerův filtr

	Medián			Wienerův			Medián - průměr	Wienerův - průměr
	6x6	12x12	15x15	6x6	12x12	15x15		
2	7.189	5.162	4.662	6.845	7.725	7.822	5.671	7.464
4	5.567	5.325	4.942	5.769	6.027	6.094	5.278	5.963
5	6.625	5.667	4.925	6.543	6.169	6.163	5.739	6.292
8	6.171	5.663	5.036	5.937	5.899	6.431	5.623	6.089
9	6.366	5.892	5.295	5.823	5.972	6.003	5.851	5.933
10	6.375	6.307	5.653	5.199	6.441	6.900	6.112	6.180
11	5.815	5.572	5.111	5.093	5.090	5.165	5.499	5.116
13	5.888	5.514	5.385	5.527	5.530	5.057	5.596	5.371
14	6.380	5.334	5.062	5.867	5.646	6.217	5.592	5.910
16	5.989	5.776	5.500	5.383	6.057	6.681	5.755	6.040
18	3.626	4.496	4.531	4.759	5.366	5.694	4.218	5.273
1	4.816	3.616	4.285	4.335	3.917	4.245	4.239	4.166
2	4.745	3.708	3.786	4.173	3.742	3.856	4.079	3.924
7	5.222	3.737	3.650	4.479	4.327	4.340	4.203	4.382
8	5.036	3.885	4.919	5.178	5.868	6.972	4.613	6.006
9	5.520	3.585	4.344	5.087	4.946	5.381	4.483	5.138
10	5.676	3.889	4.492	5.652	5.300	5.175	4.686	5.376
11	5.414	3.966	4.891	5.486	5.364	6.418	4.757	5.756



Graf 3: Hodnoty parametru NIQE v přehledném grafu – snímky z datasetu 1

V grafu jsou uvedeny průměrné hodnoty pro oba testované filtry (v tabulce sloupec medián – průměr a Wienerův – průměr). Jedná se o průměr tří použitých filtračních matic – 6x6, 12x12, 15x15.



Graf 4: Hodnoty parametru NIQE v přehledném grafu – snímky z datasetu 2

V grafu jsou uvedeny průměrné hodnoty pro oba testované filtry (v tabulce sloupec medián – průměr a Wienerův – průměr). Jedná se o průměr tří použitých filtračních matic – 6x6, 12x12, 15x15.

Jak vyplývá z grafů i tabulky pro tento parametr, je i zde vhodnější pro další zpracování filtr mediánový, jelikož hodnoty parametru NIQE v naprosté většině případů dosahují nižších hodnot než v případě Wienerova filtru. Proto byl pro další předzpracování použit právě mediánový filtr s jádrem 6x6.


7.4 Prahování a segmentace

Segmentaci obrazu je možné provádět několika možnými způsoby (viz kapitola 5). V této diplomové práci bylo využito segmentace pomocí prahování.


Cílem prahování je rozdělení obrazu do dvou či více regionů. Vždy záleží na nastaveném počtu prahovacích hodnot. V rámci této DP je očekáváno, že ledvinové kameny budou pomocí prahování segmentovány tak, aby bylo možné je odlišit od okolních struktur. V následujících podkapitolách je rozepsáno, jaké způsoby prahování byly aplikovány na požadované snímky. Bylo otestováno prahování s jednou prahovací úrovní a také s větším počtem prahovacích úrovní.

7.4.1 Analýza binarizace obrazu na základě prahování

Binarizace obrazu je v podstatě nejjednodušší funkcí, kterou je možné k prahování použít. Hlavním parametrem pro binarizaci je prahová hodnota, což je patrné z následujících snímků (viz Obrázek 37 až Obrázek 39). Práh je číselný údaj nabývající hodnoty od 0 do 1.




Obrázek 36: Princip binarizace obrazu




Obrázek 37: Binarizace obrazu

Vlevo: původní snímek, vpravo: prahování pomocí binarizace kde je prahová hodnota nastavená na hodnotu 0.5
Zeleně označena ROI, červené šipky označují struktury, které na snímku nemají co dělat.



Obrázek 38: Binarizace obrazu

Vlevo: původní snímek, vpravo: prahování pomocí binarizace kde je prahová hodnota nastavená na hodnotu 0.75
Zeleně označena ROI, červené šipky označují struktury, které na snímku nemají co dělat.



Obrázek 39: Binarizace obrazu


Vlevo: původní snímek, vpravo: prahování pomocí binarizace kde je prahová hodnota nastavená na hodnotu 1

Zeleně označena ROI, červené šipky označují struktury, které na snímku nemají co dělat.

Z obrázků výše (viz Obrázek 37, Obrázek 38 a Obrázek 39) je zřejmé, že tato funkce není příliš vhodná pro prahování ultrazvukových snímků. Hlavní nevýhodou binarizace obrazu je nedostatečná segmentace objektu zájmu od ostatních struktur – ledvinový kámen není příliš rozpoznatelný na předzpracovaném snímku, proto tato metoda prahování nebyla dále použita.


Další možností prahování, která byla v rámci diplomové práce testována, byla aplikace metody, při které je z každého snímku automaticky vypočtena prahová hodnota.

Snímek po prahování pak vypadal takto (viz Obrázek 40):



Obrázek 40: Prahování na základě vypočteného prahu – první snímek

Vlevo: původní snímek, vpravo: snímek prahován podle hodnoty vypočtené hodnoty – zeleně ROI, červeně struktury mimo LK.




Obrázek 41: Prahování na základě vypočteného prahu – druhý snímek

Vlevo: původní snímek, vpravo: snímek prahován podle hodnoty vypočtené hodnoty – zeleně ROI.

Ze snímků výše (viz Obrázek 40 a Obrázek 41) je patrné, že ani na základě vypočteného prahu stále není ledvinový kámen dostatečně oddělen od okolních struktur. Proto ani s touto metodou prahování nebylo dále pracováno při vyhodnocení práce.


Ještě jednodušší metodou pro segmentaci je odlišení zkoumaného objektů od pozadí na základě odstínu jednotlivých pixelů. Nastaví se pouze práh, který oddělí pixely, které se zbarví černě a které se zbarví bíle.



Obrázek 42: Segmentace na základě stupňů šedi jednotlivých pixelů

Vlevo: původní snímek, vpravo: práh nastaven na hodnotu 220 z klasických 256 odstínů – zeleně ROI.

Výsledek tohoto způsobu segmentace vypadá nejvhodněji pro další zpracování a následné vyhodnocení pomocí aktivních kontur, proto byl aplikován také na další snímky (viz Obrázek 43). Nevýhodou však je ruční nastavování prahové hodnoty pro každý snímek zvlášť, proto tato metoda taktéž nebyla dále aplikována.



Obrázek 43: Segmentace na základě stupňů šedi jednotlivých pixelů

Vlevo: původní snímek, vpravo: práh nastaven na hodnotu 220 z klasických 256 odstínů – zeleně ROI.

7.4.2 Multiregionální segmentace – OTSU prahování

V rámci multiregionální segmentace byla uplatněna tzv. Otsu metoda. Tato metoda je založena na principu vyhledávání optimálního prahu pro segmentaci obrazu. Tato prahová hodnota je získána na základě vnitřního rozptylu jednotlivých pixelů nebo mezi-rozptylu (zjednodušeně jde o rozhodnutí, který pixel bude eliminován a který ne). Ideálně zvolená prahová hodnota je taková, ve které je rozdíl rozptylů mezi jednotlivými pixely minimální. [15]

Matematický popis Otsu metody je dán vztahem níže:

$$\sigma_B^2 = W_b * W_f (\mu_b - \mu_f)^2 \quad (9)$$

kde:

- W_b ...váha pozadí,
- μ_b ...průměrná hodnota intenzity pozadí,
- W_f ...váha popředí,
- μ_f ...průměrná hodnota intenzity popředí.

Jednotlivé veličiny jsou počítány z následujících vztahů:

$$W_b = \sum_{i=1}^k \frac{n_i}{N} \quad (10)$$

$$\mu_b = \sum_{i=1}^k \frac{n_i * i}{N_k} \quad (11)$$

$$W_f = \sum_{i=k+1}^L \frac{n_i}{N} \quad (12)$$


$$\mu_f = \sum_{i=k+1}^L \frac{n_i * i}{N - N_k} \quad (13)$$

kde:

- L ...pixely snímku různých odstínů šedi,
- n_i ...počet pixelů daného odstínu šedi,
- N ...celkový počet pixelů ($N=n_0+n_1+n_2+\dots+n_L$),
- k ...prahovací úroveň,
- b ...pixely pozadí,
- f ...pixely popředí.

V rámci diplomové práce byla metoda multiregionální segmentace použita pro získání optimálních výsledků v oblasti extrakce ledvinových kamenů ze snímků, jelikož metoda binarizace obrazu nebyla dostatečná.

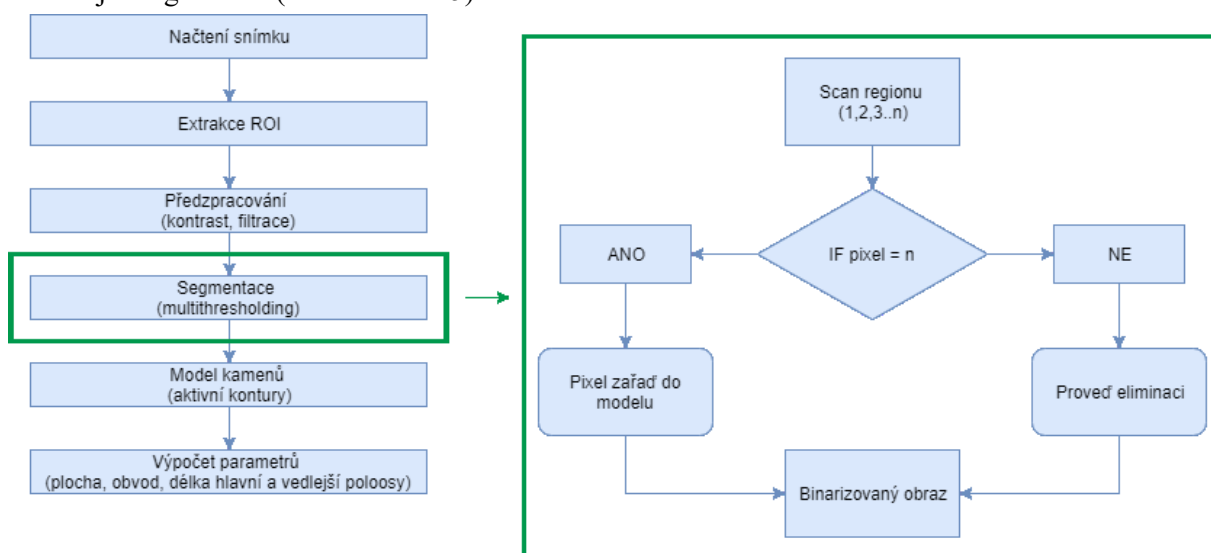
Hlavními parametry multiregionální segmentace je nepochybně počet prahů – n a počet tříd – $n + 1$.



Obrázek 44: Princip multiregionální segmentace

7.4.3 Algoritmus pro multiregionální segmentaci

Pro dosažení optimálních výsledků při vytvoření modelu LK byl pro segmentaci otestován taktéž princip využívající multiregionální segmentaci (viz 7.4.2). V rámci této metody byl navržen následující algoritmus (viz Obrázek 45).



Obrázek 45: Princip extrakce příslušné segmentační třídy v rámci multiregionální segmentace

Na základě Otsu prahování je celý snímek rozdělen do příslušného počtu regionů podle ideálně zvolených prahovacích hodnot (viz 7.4.2). Tyto regiony jsou, v rámci multiregionální segmentace, procházeny pixel po pixelu a dále vyhodnocovány. V případě, že se daný pixel rovná hodnotě regionu, ve kterém se nachází objekt zájmu, je tento pixel zahrnut do modelu. V případě opačném je tento pixel eliminován.

Ve výsledku vznikl binarizovaný obraz, kde je extrahována pouze třída obsahující požadovaný objekt. Pro ukázkou byl tento algoritmus implementován na reálný ultrazvukový snímek ledvinových kamenů (viz Obrázek 46) a následně i na snímky ostatní.




Obrázek 46: Implementace algoritmu pro multiregionální segmentaci

Vlevo: snímek rozdělen do 5 regionů, uprostřed: extrakce ROI, vpravo: extrakce třídy, ve které se nachází objekt zájmu (LK) – zeleně ROI (LK), červené šipky označují struktury mimo LK.


Na základě tohoto rozdělení je možné s obrazem dále pracovat a zobrazit si oblast zájmu nebo ledvinový kámen v závislosti na tom, jakou třídu si zobrazíme – řešeno kódem níže:

Ukázka prahování s nastavenými 2 prahy – tzn., že vznikly 3 regiony (viz Obrázek 47) a 3 prahy – 4 regiony (viz Obrázek 48).




Obrázek 47: Multiregionální segmentace – 2 prahové hodnoty

A: Nativní snímek, B: multiregionální segmentace, C: extrakce ROI, D: extrakce LK



Obrázek 48: Multiregionální segmentace – 3 prahové hodnoty


A: Nativní snímek, B: multiregionální segmentace, C: extrakce ROI, D: extrakce LK



Obrázek 49: Multiregionální segmentace – 4 prahové hodnoty

A: Nativní snímek, B: multiregionální segmentace, C: extrakce ROI, D: extrakce LK

Experimentálním šetřením bylo zjištěno, že ideální počet regionů je 6, aby bylo možné dostatečně extrahovat LK ze snímku – tzn., bylo zvoleno 5 prahových hodnot.



Obrázek 50: Multiregionální segmentace – 5 prahových hodnot

A: Nativní snímek, **B:** multiregionální segmentace, **C:** extrakce ROI, **D:** extrakce LK

V rámci OTSU segmentace byl testován větší počet nastavených prahových hodnot – konkrétně šlo o multiregionální segmentaci se 2, 3, 4 a 5 prahovými hodnotami, tzn., že snímek byl rozdělen na základě těchto prahů do 3, 4, 5 a 6 regionů.

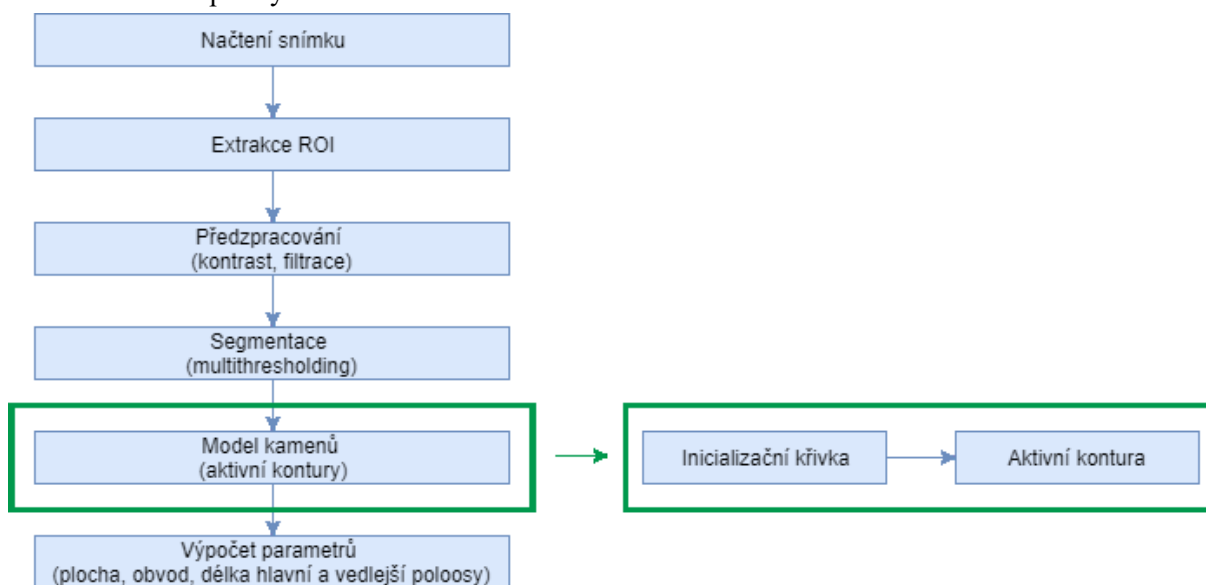
Ze snímků výše (viz Obrázek 50) je zřejmé, že se objekt zájmu (tedy ledvinové kameny) nachází v regionu, jehož pixely mají nejvyšší jasovou hodnotu (na snímcích označena žlutou barvou).

V případě rozčlenění snímků do 3 a 4 regionů je patrné, že ledvinové kameny nejsou vhodně segmentované od okolních struktur, které mají jasovou hodnotu pixelu velice podobnou, proto segmentace s takovýmto počtem regionů není vhodná pro další zpracování obrazu.

V případě rozčlenění snímků do 5 regionů byly ledvinové kameny segmentovány daleko lépe než v předcházejícím případě. Na závěr bylo taktéž otestováno rozčlenění snímků do 6 regionů, díky kterému bylo dosaženo optimálních výsledků pro další zpracování snímků – byla tedy zvolena segmentace na základě 5 prahových hodnot, které snímky rozdělily do 6 regionů.

7.5 Aktivní kontury

Posledním krokem při zpracování ultrazvukového snímku v rámci této diplomové práce je využití aktivních kontur pro vytvoření modelu LK.



Obrázek 51: Aktivní kontury

Základem pro aktivní konturu je inicializační křivka, která kopíruje hranice analyzovaného objektu. Následně je na základě energií v obraze tato označená oblast vyhodnocena a objekt ohraničen červenou křivkou.


Matematicky je aktivní kontura popsána následujícími rovnicemi:

$$E_{snake}^*(v) = \int_0^1 E_{snake}(v(s))ds = \int_0^1 E_{int}(v(s)) + E_{ext}(v(s))ds = \int_0^1 E_{int}(v(s)) + E_{image}(v(s)) + E_{con}(v(s))ds \quad (14)$$

kde:

- E_{int} ...interní energie,
- E_{ext} ...externí energie,
- E_{image} ...energie vypočítána z obrazu,
- E_{con} ...body inicializační křivky.

V rámci této práce bylo pro vykreslení aktivní kontury v MATLABu zvoleno příkazu *imfreehand*, který funguje na principu vykreslení aktivní kontury na základě inicializační křivky. Nejdříve je nutné interaktivně vybrat oblast (viz Obrázek 52), ve které se ledvinový kámen nachází a následně je po vstupu uživatele vykreslena taktéž aktivní kontura (viz Obrázek 53 – Obrázek 56).



Obrázek 52: Interaktivní zvolení oblasti ledvinového kamene


Vlevo: Segmentace oblasti zájmu, vpravo: extrakce zájmového objektu – modře inicializační křivka, červeně aktivní kontura.

Nejdůležitějším parametrem při vykreslování aktivní kontury je maximální počet iterací. Čím vyšší počet iterací je zvolen pro aktivní konturu, tím přesněji je objekt segmentován pomocí červené křivky. Níže je možné vidět dva výsledky, které se liší právě počtem iterací – v prvním případě (viz Obrázek 53 a Obrázek 54) je počet iterací nastaven na hodnotu 100, v druhém případě (viz Obrázek 55 a Obrázek 56) je počet iterací nastaven na hodnotu 900.




Obrázek 53: Aktivní kontury – inicializační křivka (modře), aktivní kontura (červeně)

Počet iterací v tomto případě nastaven na hodnotu 100



Obrázek 54: Aktivní kontury – přiblížení

Počet iterací v tomto případě nastaven na hodnotu 100 (jedná se pouze o přiblížení - Obrázek 53)



Obrázek 55 Aktivní kontury – inicializační křivka (modře) a aktivní kontura (červeně)

Počet iterací v tomto případě nastaven na hodnotu 900



Obrázek 56 Aktivní kontury – přiblížení


Počet iterací v tomto případě nastaven na hodnotu 900 (jedná se pouze o přiblížení - Obrázek 55)

Z výše zobrazených snímků a aktivních kontur je zřejmé, že čím vyšší počet iterací je při využití aktivních kontur zvolen, tím lépe je daný objekt ohraničen.

7.6 Testování navrženého modelu na reálných klinických datech


Pro vyhodnocení výsledků praktické části diplomové práce bylo využito především dvou výpočtů. Prvním výpočtem byl získán počet bílých pixelů na snímku (tedy těch, které symbolizují ledvinový kámen na snímku, který byl předzpracován a segmentován), druhé číslo je získáno výpočtem pixelů, které se nacházejí na uvnitř aktivní kontury (červené křivky) – toto je zpracováno níže (viz Tabulka 3). Následně jsou zobrazeny snímky jak nativní, extrahovaná ROI, tak segmentované s využitím aktivních kontur.

Nutno podotknout, že ne všechny UZV snímky, které byly poskytnuty, je možné použít pro zpracování a to vzhledem k ne příliš velké kvalitě ultrazvukového zobrazení přístroje nemocnice. V této kapitole je uveden pouze zlomek příkladů na klinických datech. Zbytek snímků je uveden v přílohách DP (viz Výsledky finálních modelů).




Obrázek 57: Snímek číslo 2 – data set 1

A: původní snímek, **B:** segmentace vybrané oblasti zájmu, **C:** segmentace ledvinového kamene, **D:** inicializační křivka (modře) a aktivní kontura (červeně): počet iterací – 1600.




Obrázek 58: Snímek číslo 4 – data set 1

A: původní snímek, **B:** segmentace vybrané oblasti zájmu, **C:** segmentace ledvinového kamene, **D:** inicializační křivka (modře) a aktivní kontura (červeně): počet iterací – 1600.




Obrázek 59: Snímek číslo 5 – data set 1

A: původní snímek, **B:** segmentace vybrané oblasti zájmu, **C:** segmentace ledvinového kamene, **D:** inicializační křivka (modře) a aktivní kontura (červeně) : počet iterací – 1600.




Obrázek 60: Snímek číslo 16 – data set 1

A: původní snímek, **B:** segmentace vybrané oblasti zájmu, **C:** segmentace ledvinového kamene, **D:** inicializační křivka (modře) a aktivní kontura (červeně) : počet iterací – 1600.




Obrázek 61: Snímek číslo 18 – data set 1

A: původní snímek, **B:** segmentace vybrané oblasti zájmu, **C:** segmentace ledvinového kamene, **D:** inicializační křivka (modře) a aktivní kontura (červeně) : počet iterací – 1600.




Obrázek 62: Snímek číslo 1 – data set 2

A: původní snímek, **B:** segmentace vybrané oblasti zájmu, **C:** segmentace ledvinového kamene, **D:** inicializační křivka (modře) a aktivní kontura (červeně) : počet iterací – 1600.



Obrázek 63: Snímek číslo 7 – data set 2

A: původní snímek, **B:** segmentace vybrané oblasti zájmu, **C:** segmentace ledvinového kamene, **D:** inicializační křivka (modře) a aktivní kontura (červeně) : počet iterací – 1600.



Obrázek 64: Snímek číslo 9 – data set 2

A: původní snímek, **B:** segmentace vybrané oblasti zájmu, **C:** segmentace ledvinového kamene, **D:** inicializační křivka (modře) a aktivní kontura (červeně) : počet iterací – 1600.


Na závěr je zde tabulka obsahující číselné hodnoty (viz Tabulka 3).

Tabulka 3: Srovnání referenčního modelu s navrženým modelem LK


První sloupec udává číslo snímku z daného data setu – první část snímků označená kurzívou je z 1. data setu, druhá část je z 2. data setu (odděleno volným řádkem).

	Referenční model	Navržený model LK	Rozdíl [%]
<i>2</i>	47016	41910	10.86
<i>4</i>	15324	6004	60.82
<i>5</i>	10680	10059	5.81
<i>8</i>	7823	7826	0.04
<i>9</i>	48288	48257	0.06
<i>10</i>	8726	8330	4.54
<i>11</i>	12498	9547	23.61
<i>13</i>	13328	3772	71.70
<i>14</i>	11206	10878	2.93
<i>16</i>	14765	8186	44.56
<i>18</i>	11533	8483	26.45
<i>1</i>	64540	62562	3.06
<i>2</i>	50057	38925	22.24
<i>7</i>	88395	82465	6.71
<i>8</i>	98400	99529	1.15
<i>9</i>	22786	14672	35.61
<i>10</i>	46928	38951	17.00
<i>11</i>	47016	41910	10.86

Sloupeček s názvem referenční model obsahuje hodnoty, které jsou vypočítány na základě více úrovněvého prahování (výpočet bílých pixelů na snímku). Sloupeček navržený model LK obsahuje počet pixelů, které se nacházejí na snímku uvnitř aktivní kontury. Sloupeček rozdíl [pixely] obsahuje rozdíl dvou předešle zmíněných sloupců – poslední sloupec rozdíl [%] dopočítává procentuální hodnotu rozdílů dvou předešlých sloupců.



Graf 5: Srovnání referenčního modelu s navrženým modelem



Graf 6: Rozdíl [%] mezi navrženým modelem a referenčními hodnotami

Na základě výsledné tabulky bylo taktéž vytvořeno grafické zobrazení hodnot. V grafu výše (viz Graf 5 a Graf 6) je možné vidět, že odchylky ve výpočtech pixelů v některých případech jsou velice významné např.: snímek 13 z 1. data setu či snímek 9 z 2. data setu.

Tyto výrazné odchylky jsou pravděpodobně způsobeny výskytem dalších struktur, které mají i přes zvolený počet segmentačních tříd podobnou hodnotu jasu jako ledvinové kameny (oblast zájmu). Proto jsou tyto bílé pixely započítány do referenčního modelu i přesto, že nejsou součástí modelu LK. V případě aplikace aktivních kontur jsou tyto struktury eliminovány, a tudíž se tyto bílé pixely na snímku dále nevyskytují a nejsou započítávány.

Posledním bodem je extrakce vlastností modelu ledvinových kamenů jako jsou plocha (viz výše – srovnání plochy referenčního modelu a navrženého modelu), obvod a délka hlavní a vedlejší poloosy. Všechny tyto hodnoty jsou uloženy v souborech, které je možné načíst v programu MATLAB, ale také v tabulce níže (viz Tabulka 4).

Tabulka 4: Extrahované vlastnosti modelu LK

	Obvod	Hlavní poloosa	Vedlejší poloosa
2	1053.73, 208.91, 20.62	197.74, 56.36, 8.762	102.06, 32.74, 4.25
4	289.93, 276.84, 94.26	99.41, 90.81, 28.93	42.06, 36.99, 19.35
5	378.06, 360.15, 304.10	98.59, 93.53, 71.76	67.13, 54.79, 43.04
8	468.28, 224.34, 38.31	136.75, 59.53, 15.09	65.25, 38.58, 6.25
9	1942.85, 604.63, 383.61	296.02, 201.99, 128.04	166.90, 69.01, 47.29
10	575.03	158.95	70.02
11	519.42, 198.78, 187.40	141.52, 66.85, 61.74	63.153, 28.799, 25.069
13	345.98	116.43	45.00
14	820.80	194.48	84.30
16	464.06	166.30	66.28
18	534.69, 130.06, 104.50	207.77, 47.09, 34.11	45.96, 18.94, 18.90
1	2327.63, 316.38, 141.52	333.85, 86.73, 53.70	234.38, 28.63, 21.51
2	1192.63, 1036.89, 926.76	232.35, 221.08, 142.28	93.20, 92.70, 91.72
7	4866.97, 465.65, 332.28	731.03, 83.70, 74.81	252.17, 72.15, 39.76
8	6005.26, 482.74, 409.72	695.31, 111.18, 95.56	207.04, 40.31, 37.24
9	1028.59, 317.85, 79.09	156.63, 64.10, 24.87	118.64, 35.77, 11.43
10	1109.85, 730.07, 709.62	177.56, 166.07, 149.15	94.76, 71.40, 70.73
11	1117.51, 1111.39, 718.66	201.78, 175.36, 116.36	124.65, 111.67, 72.96

Vzhledem k faktu, že na některých snímcích je v modelu zahrnuto více samostatných objektů, tak i v tabulce je u těchto snímků více hodnot pro všechny parametry.

8 Závěr

V rámci diplomové práce jsem měla možnost se dozvědět více nejen o metodách segmentace obrazu, ale také celkově o onemocněních ledvin, metodách předzpracování obrazu, jakým způsobem tyto metody vyhodnotit, jaké parametry jsou důležité, a také o principech, na kterých všechny metody, které jsou v DP zmíněné, fungují. Měla jsem také možnost být v kontaktu s MUDr. Hájkovou z urologické kliniky v Ostravě, které velice děkuji za poskytnutí snímků pro praktickou část.

V rámci předzpracování obrazu jsem testovala dva typy filtrů a to mediánový a Wienerův. Tyto dva filtry jsem postupně aplikovala na všechny snímky, které jsem v práci použila. Na vyhodnocení jsem využila dvou parametrů a to brisque a niqe – na základě hodnot, které jsem dostala, jsem se rozhodla, dále využít snímek, který byl filtrován mediánovým filtrem, jelikož, jak je z tabulky i grafů zřejmé, mediánové hodnoty byly nižší než hodnoty Wienerova filtru, což bylo u těchto parametrů rozhodující.

V rámci segmentačního algoritmu jsem otestovala různé metody. Nejdříve jsem testovala nejjednodušší metodu segmentace, kterou je binarizace, nicméně tato metoda nebyla pro další zpracování dostatečná. Ačkoliv jsem zkoušela nastavit různé prahové úrovně, nebylo možné ledvinový kámen dostatečně oddělit od okolních struktur. Ani konkrétním výpočtem prahové hodnoty pro každý snímek zvlášť jsem nedosáhla úspěchu. Proto jsem se rozhodla pro multiregionální segmentaci, která rozdělila celý snímek na základě rozptylu jasových hodnot do několika regionů – na základě experimentálního měření jsem zjistila, že ideální počet regionů je 6 regionů a tedy bylo použito 5 prahových hodnot. Ledvinové kameny, tedy oblast zájmu, se nacházela ve třídě 6 (na snímcích označena žlutou barvou). Na snímcích se vyskytly i struktury, které měly stejnou třídu (tedy 6), ale k modelu nepatřily, proto jsem následně zvolila ještě metodu segmentace na bázi aktivních kontur. Pomocí inicializační křivky jsem ohraničila pouze struktury ledvinových kamenů, které byly následně ohraničené červenou křivkou.

Posledním krokem byla extrakce parametrů modelu LK – konkrétně šlo o plochu, obvod a délku hlavní a vedlejší poloosy.

Výpočet plochy byl počítán dvěma způsoby – první bylo počítání bílých pixelů po multiregionální segmentaci a druhý výpočet pixelů, které ležely uvnitř aktivní kontury. Tyto hodnoty byly dále zaznamenány do tabulky. Z té je zřejmé, že se hodnoty referenčního modelu proti tomu navrženému v některých případech velice liší. Toto je způsobeno především přítomností struktur po segmentaci, které ležely ve stejné třídě jako ledvinové kameny – po aplikaci aktivních kontur tyto struktury byly potlačeny a proto se do plochy nepočítaly, protože neleží uvnitř křivky.

Pro mne samotnou byla práce obrovským přínosem, nicméně je možné ji ještě stále vylepšovat. Například pro aktivní kontury by bylo možné použít jinou metodu, např.: marching level set či vytvořit softwarovou aplikaci fungující na tomto principu s výpočtem parametrů.

9 Použitá literatura a internetové zdroje


1. HOLIBKOVÁ, Alžběta a Stanislav LAICHMAN. Přehled anatomie člověka. 5. vyd. Olomouc: Univerzita Palackého v Olomouci, 2010. ISBN 978-80-244-2615-0.
2. STRÍTESKÝ, Jan. Patologie: [učebnice pro zdravotnické školy a bakalářské studium]. Olomouc: Epava, 2001. ISBN 80-86297-06-3.
3. PENHAKER, Marek a Martin AUGUSTYNEK. Zdravotnické elektrické přístroje 1. Ostrava: Vysoká škola báňská - Technická univerzita Ostrava, 2013. ISBN 978-80-248-3107-7.
4. GONZALEZ, Rafael C., Richard E. WOODS a Steven L. EDDINS. Digital Image processing using MATLAB. Upper Saddle River, NJ: Pearson/Prentice Hall, c2004. ISBN 0-13-008519-7.
5. MCANDREW, Alasdair. Introduction to digital image processing with Matlab. Australia: Thomson course technology, 2004. ISBN 0-534-40011-6.
6. LIČEV, Lačezar. Systém FOTOMng: architektura, funkce a použití. Praha: BEN - technická literatura, 2015. ISBN 978-80-7300-521-4.
7. Urolitiáza – onemocnění močovými kameny. *Česká urologická společnost* [online]. České Budějovice [cit. 2019-04-28]. Dostupné z: <http://www.cus.cz/pro-pacienty/diagnozy/urolitiaza-onemocneni-mocovymi-kameny/>
8. HOLMANNOVÁ, Drahomíra. Ledvinové kameny. *Symptomy* [online]. [cit. 2019-04-28]. Dostupné z: <https://www.symptomy.cz/nemoc/ledvinove-kameny>
9. Urolitiáza - močové kameny. *Česká nadace pro nemoci ledvin* [online]. 2018 [cit. 2019-04-28]. Dostupné z: <http://www.nadaceledviny.cz/informacni-brozurky/urolitiaza-mocove-kameny>
10. VILÍMOVSKÝ, Michal. *Prevence ledvinových kamenů* [online]. 2019 [cit. 2019-04-28]. Dostupné z: <https://cs.medlicker.com/1200-prevence-ledvinovych-kamenu#co-jsou-ledvinove-kameny>
11. JÜTTNEROVÁ, Sandra. Fyzika ultrazvuku. *Ultrasonografie* [online]. 2016 [cit. 2019-04-28]. Dostupné z: http://www.jtarchitekt.cz/fyzika_ultrazvuku.html#1_fyzika_ultrazvuku
12. Pedagogická fakulta [online]. České Budějovice [cit. 2019-04-28]. Dostupné z: http://www.pf.jcu.cz/stru/katedry/fyzika/prof/Tesar/diplomky/obr_dopl_optika/optika/zakl_prvky/odraz_lom.htm
13. EDAN U50 - přenosný ultrazvuk s barevným dopplerem. *Veterinární a humánní přístroje* [online]. 2010 [cit. 2019-04-28]. Dostupné z: https://www.texdan.com/index.php?lng=&cont=produkt_detail&produkt=EDAN_U50hum
14. ZÁVODNÍKOVÁ, Barbora. *Vývoj nástrojů pro segmentaci mozkových komor a tumoru mozku na snímcích za účelem následného vyhodnocení zájmových objektů* [online]. Ostrava, 2018 [cit. 2019-04-29]. Dostupné z: <http://hdl.handle.net/10084/128507>. Diplomová práce. Vysoká škola báňská - Technická univerzita Ostrava.
15. VALOŠEK, Jan. *Software pro vizualizaci a kvantitativní vyhodnocení cévních kalcifikací* [online]. Ostrava, 2017 [cit. 2019-04-29]. Dostupné z: <http://hdl.handle.net/10084/119119>. Diplomová práce. Vysoká škola báňská - Technická univerzita Ostrava.
16. DRAHORÁDOVÁ, Lucie. *Vývoj nástrojů pro segmentace a volumetrie mozku u RS - roztroušené sklerózy za účelem následného vyhodnocení zájmových objektů* [online]. Ostrava,


- 2018 [cit. 2019-04-29]. Dostupné z: <http://hdl.handle.net/10084/133060>. Diplomová práce. Vysoká škola báňská - Technická univerzita Ostrava.
17. *Vyšetřovací metody* [online]. 2013 [cit. 2019-04-28]. Dostupné z: <http://pfyziolklin.upol.cz/?p=8679>
 18. STRAKA, Stanislav. *Segmentace obrazu*. Brno, 2009. Dostupné také z: <https://is.muni.cz/th/tzp80/dp.pdf>. Diplomová práce. Masarykova univerzita.
 19. M mode. *Medison* [online]. [cit. 2019-04-28]. Dostupné z: <https://www.medison.ru/ultrasound/gal404.htm>
 20. KALANNAGARI, Viswanath a Gunasundari RAMALINGAM. *Analysis and Implementation of Kidney Stone Detection by Reaction Diffusion Level Set Segmentation Using Xilinx System Generator on FPGA* [online]. Indie, 2015 [cit. 2019-04-29]. Dostupné z: <http://dx.doi.org/10.1155/2015/581961>
 21. AKKASALIGAR, Prema T., Sunanda BIRADAR a Veena KUMBAR. Kidney stone detection in computed tomography images. *2017 International Conference On Smart Technologies For Smart Nation (SmartTechCon)* [online]. IEEE, 2017, 2017, , 353-356 [cit. 2019-04-29]. DOI: 10.1109/SmartTechCon.2017.8358395. ISBN 978-1-5386-0569-1. Dostupné z: <https://ieeexplore.ieee.org/document/8358395/>
 22. AKKASALIGAR, Prema T. a Sunanda BIRADAR. Diagnosis of renal calculus disease in medical ultrasound images. *2016 IEEE International Conference on Computational Intelligence and Computing Research (ICCIC)* [online]. IEEE, 2016, 2016, , 1-5 [cit. 2019-04-29]. DOI: 10.1109/ICCIC.2016.7919642. ISBN 978-1-5090-0612-0. Dostupné z: <http://ieeexplore.ieee.org/document/7919642/>
 23. SRIDHAR, S., N. KUMARAVEL a K. S. EASWARAKUMAR. Segmentation of renal calculi in ultrasound images. *Medical Informatics and the Internet in Medicine* [online]. 2009, 27(4), 229-236 [cit. 2019-04-29]. DOI: 10.1080/1463923021000054217. ISSN 1463-9238. Dostupné z: <http://www.tandfonline.com/doi/full/10.1080/1463923021000054217>

Přílohy


I. Výsledky regionální segmentace


Níže jsou uvedeny výstupy multiregionální segmentace pro zpracovávané snímky z prvního data setu. A: nativní snímek extrahovaný na ROI, B: aplikace multiregionální segmentace s 5 prahovými hodnotami – rozčlenění snímku do 6 regionů – LK ve žlutě zbarveném regionu, C: segmentace LK.





Níže jsou uvedeny výstupy multiregionální segmentace pro zpracovávané snímky z druhého data setu. **A:** nativní snímek extrahovaný na ROI, **B:** aplikace multiregionální segmentace s 5 prahovými hodnotami – rozčlenění snímku do 6 regionů – LK ve žlutě zbarveném regionu, **C:** segmentace LK.







II. Výsledky finálních modelů

V rámci příloh jsou uvedeny také veškeré výstupy modelů LK. Pro každý snímek jsou uvedeny 4 výstupy: **A** – nativní snímek, **B** – segmentace ROI, **C** – segmentace LK, **D** – aplikace aktivních kontur.

Níže jsou uvedeny výstupy segmentace na bázi aktivních kontur pro zpracovávané snímky z prvního datasetu.





Dále jsou uvedeny výstupy segmentace na bázi aktivních kontur pro zpracovávané snímky z druhého datasetu.

